



**TUGAS AKHIR – SS141501**

**PERAMALAN *INFLOW* DAN *OUTFLOW*  
UANG KARTAL DI PROVINSI JAWA BARAT  
MENGUNAKAN *HYBRID ARIMAX-NEURAL  
NETWORK* DAN GARCH**

**JULIYANTO  
NRP. 1313 100 014**

**Dosen Pembimbing  
Dr. Suhartono**

**PROGRAM STUDI SARJANA  
DEPARTEMEN STATISTIKA  
FAKULTAS MATEMATIKA DAN ILMU PENGETAHUAN ALAM  
INSTITUT TEKNOLOGI SEPULUH NOPEMBER  
SURABAYA 2017**



**TUGAS AKHIR – SS141501**

**PERAMALAN *INFLOW* DAN *OUTFLOW*  
UANG KARTAL DI PROVINSI JAWA BARAT  
MENGUNAKAN *HYBRID* ARIMAX-*NEURAL*  
*NETWORK*  
DAN GARCH**

**Juliyanto  
NRP. 1313 100 014**

**Dosen Pembimbing  
Dr. Suhartono**

**PROGRAM STUDI SARJANA  
DEPARTEMEN STATISTIKA  
FAKULTAS MATEMATIKA DAN ILMU PENGETAHUAN ALAM  
INSTITUT TEKNOLOGI SEPULUH NOPEMBER  
SURABAYA 2017**



**FINAL PROJECT – SS141501**

**INFLOW AND OUTFLOW FORECASTING  
OF CURRENCY IN WEST JAVA USING *HYBRID*  
ARIMAX-*NEURAL NETWORK* AND GARCH**

**Juliyanto  
NRP. 1313 100 014**

**Supervisor  
Dr. Suhartono**

**UNDERGRADUATE PROGRAMME  
DEPARTMENT OF STATISTICS  
FACULTY OF MATHEMATICS AND NATURAL SCIENCES  
INSTITUT TEKNOLOGI SEPULUH NOPEMBER  
SURABAYA 2017**

## LEMBAR PENGESAHAN

### **PERAMALAN INFLOW DAN OUTFLOW UANG KARTAL DI PROVINSI JAWA BARAT MENGUNAKAN *HYBRID ARIMAX-NEURAL NETWORK* DAN GARCH**

#### **TUGAS AKHIR**

**Diajukan Untuk Memenuhi Salah Satu Syarat  
Memperoleh Gelar Sarjana Sains  
pada**

**Program Studi Sarjana Departemen Statistika  
Fakultas Matematika dan Ilmu Pengetahuan Alam  
Institut Teknologi Sepuluh Nopember**

**Oleh :**

**Juliyanto**

**NRP. 1313 100 014**

**Disetujui oleh Pembimbing:**

**Dr. Suhartono**

**NIP. 19710929 199512 1 001**



**Mengetahui,  
Kepala Departemen**



**Dr. Suhartono**

**NIP. 19710929 199512 1 001**



**SURABAYA, JULI 2017**

**PERAMALAN *INFLOW* DAN *OUTFLOW*  
UANG KARTAL DI PROVINSI JAWA BARAT  
MENGUNAKAN *HYBRID* ARIMAX-NEURAL  
NETWORK DAN GARCH**

**Nama : Juliyanto**  
**NRP : 1313100014**  
**Departemen : Statistika**  
**Dosen Pembimbing : Dr. Suhartono**

**Abstrak**

*Uang kartal merupakan uang yang dikeluarkan oleh Bank Indonesia (BI) sebagai alat pembayaran tunai serta salah satu alat utama perekonomian suatu negara yang memegang peranan penting, dimana pada umumnya masyarakat masih menggunakan uang kartal untuk keperluan transaksi ekonomi. Tujuan pada penelitian ini adalah melakukan peramalan jumlah peredaran uang kartal yang masuk dan keluar di provinsi Jawa Barat menggunakan Hybrid ARIMAX-NN, dan GARCH. Hybrid merupakan gabungan dari model linier dan non-linier serta cenderung menunjukkan performa lebih baik jika dibandingkan dengan peramalan tunggal. Data yang digunakan adalah inflow dan outflow uang kartal di Provinsi Jawa Barat periode Januari 2004 hingga Desember 2016. Penelitian ini akan dimulai dengan menganalisis data studi simulasi skenario 1 hingga 4 yang mengandung pola tren, musiman, dan variasi kalender. Metode terbaik dalam menganalisis skenario tersebut adalah Hybrid ARIMAX-NN. Model yang tepat untuk outflow uang kartal di Kantor Perwakilan BI Provinsi Jawa Barat menggunakan Hybrid ARIMAX-NN dengan nilai RMSE out-sample sebesar 1,238 sedangkan model yang tepat untuk inflow uang kartal*

*menggunakan ARIMAX dengan nilai RMSE out-sample sebesar 1,851.*

***Kata Kunci : Bank Indonesia, Hybrid ARIMAX-NN, Inflow, Outflow, Neural Network, Uang Kartal***

# **INFLOW ANF OUTFLOW FORECASTING OF CURRENCY IN WEST JAVA USING HYBRID ARIMAX-NEURAL NETWORK AND GARCH**

**Name : Juliyanto**  
**NRP : 1313100014**  
**Department : Statistics**  
**Supervisor : Dr. Suhartono**

## **Abstract**

*Cartal money is the currency issued by Bank Indonesia (BI) as a means of payment in cash and plays an important role as the main tools of the economy of the country where people still use currency for the purposes of economic transactions. The purpose of this study is to forecast the amount of currency circulation in West Java province using Hybrid ARIMAX-NN, and GARCH. Hybrid is a combination between linear and non-linear models and tends to show better performance compared to single forecasting. The data used are currency inflow and outflow in West Java Province from January 2004 to December 2016. This study will begin by analyzing simulation study data of scenarios 1 to 4 that contain trend patterns, seasonal patterns, and calendar variations. The best method of analyzing those scenarios is Hybrid ARIMAX-NN. The proper model for currency outflow at Bank Indonesia Representative Office of West Java Province is Hybrid ARIMAX-NN with RMSE out-sample value of 1.238. While the proper model for currency inflow at Bank Indonesia Representative Office of West Java Province is ARIMAX with RMSE out-sample value of 1.851.*

**Keyword : ARIMAX, Bank Indonesia, Hybrid ARIMAX-NN,  
Inflow, Neural Network, Outflow**

*Halaman ini sengaja dikosongkan*



## KATA PENGANTAR

Puji syukur penulis panjatkan kehadiran Tuhan Yang Maha Esa atas segala berkah-Nya, sehingga penulis dapat menyelesaikan Tugas Akhir yang berjudul **“Peramalan *Inflow* dan *Outflow* Uang Kartal di Provinsi Jawa Barat Menggunakan *Hybrid* ARIMAX-NN dan GARCH”**.

Dalam penyelesaian tugas akhir ini, tentu tidak terlepas dari bantuan serta dukungan berbagai pihak yang telah terlibat baik secara materil maupun moril. Oleh karena itu, pada kesempatan ini penulis menyampaikan rasa terima kasih kepada:

1. Dr. Suhartono selaku dosen pembimbing Tugas Akhir, dosen wali, serta Ketua Departemen Statistika ITS yang telah memberikan banyak bimbingan dan saran selama masa perkuliahan dan dalam pengerjaan tugas akhir.
2. Imam Safawi A, M.Si dan Dra. Kartika Fithriasari, M.Si, selaku dosen penguji yang telah memberikan banyak bimbingan dan saran selama perbaikan proses Tugas Akhir.
3. Dr. Sutikno, M.Si selaku Kepala Departemen Statistika ITS yang membantu secara administrasi dalam proses penyusunan Tugas Akhir.
4. Seluruh dosen dan karyawan di Departemen Statistika ITS yang telah memberikan banyak ilmu pengetahuan, pengalaman serta wejangan kepada penulis selama menempuh proses perkuliahan.
5. Bapak, Ibu, Kakak-Kakak, dan keluarga besar penulis atas segala doa dan dukungan materi serta motivasi sehingga bisa menyelesaikan tugas akhir dengan baik.
6. Bapak Soekowardojo, Bapak Azka, Bapak Wahyu, Bapak Aswin, Ibu Poppi, Ibu Dian, Ibu Dewy, Ibu Nisa, Ibu Devy Bapak Nana, serta Bu Eka senantiasa membimbing dan memberi wejangan & masukan selama Kerja Praktik serta pengambilan data Tugas Akhir di KPw Bank Indonesia Provinsi Jawa Barat.

7. Sahabat penulis selama masa perkuliahan, Delinda, Alicia, Iza, Aulia, Win, Dimas, Esis, Aris, atas dukungan, motivasi, serta semangat dalam suka maupun duka.
8. Rekan seperjuangan Tugas Akhir, terkhusus Desak, Novi Ajeng, Farah, Dina, Raka atas motivasi, semangat dan ilmu dalam mengerjakan Tugas Akhir.
9. Sahabat Sobat Bumi Surabaya, Rizal, Boci, Dwi, Fara, Iqbal, dan Siti atas kebersamaan dan motivasi dalam mengerjakan Tugas Akhir.
10. Rekan-rekan Statistika ITS angkatan 2013 yang telah memberikan semangat, motivasi, dan berjuang bersama-sama dalam menyelesaikan perkuliahan di Departemen Statistika FMIPA ITS
11. Semua pihak yang telah membantu yang tidak dapat disebutkan satu per satu dalam penyusunan Tugas Akhir ini.

Penulis menyadari bahwa Tugas Akhir ini jauh dari kata sempurna, karena sesungguhnya hanya Tuhanlah yang maha sempurna. Semoga Tugas Akhir ini memberikan kemanfaatan terhadap pihak yang membutuhkan serta menambah pengetahuan..

Surabaya, Juli 2017

Penulis

## DAFTAR ISI

	Halaman
<b>HALAMAN JUDUL</b> .....	i
<b>COVER PAGE</b> .....	iii
<b>LEMBAR PENGESAHAN</b> .....	v
<b>ABSTRAK</b> .....	vii
<b>ABSTRACT</b> .....	ix
<b>KATA PENGANTAR</b> .....	xi
<b>DAFTAR ISI</b> .....	xiii
<b>DAFTAR GAMBAR</b> .....	xv
<b>DAFTAR TABEL</b> .....	xix
<b>DAFTAR LAMPIRAN</b> .....	xxv
<b>BAB I PENDAHULUAN</b> .....	1
1.1 Latar Belakang .....	1
1.2 Rumusan Masalah .....	6
1.3 Tujuan Penelitian .....	6
1.4 Manfaat Penelitian .....	7
1.5 Batasan Masalah .....	7
<b>BAB II TINJAUAN PUSTAKA</b> .....	9
2.1 Analisis Time Series .....	9
2.2 Model ARIMA .....	9
2.2.1 Identifikasi Model <i>Time Series</i> .....	12
2.2.2 Estimasi Parameter .....	14
2.2.3 Cek Diagnosa.....	16
2.2.4 Peramalan .....	18
2.2.5 Pemilihan Model Terbaik .....	19
2.3 Model ARIMAX .....	19
2.4 Uji Linieritas .....	20
2.5 <i>Neural Network</i> .....	21
2.6 Model ARCH dan GARCH .....	24
2.7 Model <i>Hybrid</i> .....	26
2.8 <i>Inflow</i> dan <i>Outflow</i> Uang Kartal .....	27

<b>BAB III METODOLOGI PENELITIAN</b> .....	29
3.1 Sumber Data.....	29
3.2 Variabel Penelitian .....	29
3.3 Langkah Penelitian.....	31
3.4 Diagram Alir .....	35
<b>BAB IV ANALISIS DAN PEMBAHASAN</b> .....	39
4.1 Studi Simulasi .....	39
4.1.1 Skenario 1 .....	40
4.1.2 Skenario 2.....	53
4.1.3 Skenario 3.....	66
4.1.4 Skenario 4.....	80
4.1.5 Perbandingan Akurasi Peramalan.....	95
4.2 Karakteristik <i>Inflow</i> dan <i>Outflow</i> Uang Kartal di Provinsi Jawa Barat.....	100
4.3 Model ARIMAX <i>Outflow</i> dan <i>Inflow</i> Uang Kartal.....	105
4.3.1 Model ARIMAX <i>Outflow</i> Uang Kartal .....	108
4.3.2 Model ARIMAX <i>Inflow</i> Uang Kartal .....	117
4.4 Model <i>Neural Network Outflow</i> dan <i>Inflow</i> Uang Kartal ..	126
4.4.1 Model <i>Neural Network Outflow</i> Uang Kartal .....	126
4.4.2 Model <i>Neural Network Inflow</i> Uang Kartal.....	128
4.5 Model <i>Hybrid ARIMAX-NN Outflow</i> dan <i>Inflow</i> Uang Kartal.....	129
4.5.1 Model <i>Neural Network Outflow</i> Uang Kartal .....	130
4.5.2 Model <i>Neural Network Inflow</i> Uang Kartal.....	132
4.6 Perbandingan Hasil Akurasi Peramalan .....	135
<b>BAB V KESIMPULAN DAN SARAN</b> .....	141
5.1 Kesimpulan .....	141
5.2 Saran.....	142
<b>DAFTAR PUSTAKA</b> .....	143
<b>LAMPIRAN</b> .....	147
<b>BIODATA PENULIS</b> .....	199

## DAFTAR GAMBAR

	<b>Halaman</b>
Gambar 2.1	Arsitektur Jaringan Multilapis ..... 22
Gambar 2.2	Fungsi Sigmoid Biner..... 23
Gambar 2.3	Fungsi Linier..... 23
Gambar 3.1	Diagram Alir Penelitian..... 35
Gambar 3.2	Diagram Alir Model ARIMAX ..... 36
Gambar 3.3	Diagram Alir Model NN..... 37
Gambar 3.4	Diagram Alir Model <i>Hybrid</i> ..... 38
Gambar 4.1	(a) <i>Time Series plot</i> data simulasi replikasi pertama, (b) <i>Scatter plot</i> untuk komponen residual dengan lag 1, (c) <i>Box plot</i> data simulasi, dan (d) <i>Box plot</i> data simulasi tanpa tren Skenario 1 ..... 39
Gambar 4.2	<i>Plot</i> ACF dan PACF Residal Regresi <i>Time Series</i> Replikasi Satu ..... 42
Gambar 4.3	<i>Plot</i> PACF Replikasi (a) satu, (b) dua, (c) tiga, (d) empat, dan (e) lima ..... 48
Gambar 4.4	Arsitektur FFNN model terbaik (a) satu, (b) dua, (c) tiga, (d) empat, dan (e) lima Skenario 1 .. 50
Gambar 4.5	Arsitektur model terbaik Replikasi (a) satu, (b) dua, (c) tiga, (d) empat, dan (e) lima Skenario 1 .. 52
Gambar 4.6	(a) <i>Time Series plot</i> data simulasi replikasi pertama, (b) <i>Scatter plot</i> untuk komponen residual dengan lag 1, (c) <i>Box plot</i> data simulasi, dan (d) <i>Box plot</i> data simulasi tanpa tren Skenario 2..... 54
Gambar 4.7	<i>Plot</i> ACF dan PACF Residal Regresi <i>Time Series</i> Replikasi Satu ..... 56
Gambar 4.8	<i>Plot</i> PACF Replikasi (a) satu, (b) dua, (c) tiga, (d) empat, dan (e) lima Skenario 2 ..... 60
Gambar 4.9	Arsitektur FFNN Model Terbaik (a) satu, (b) dua, (c) tiga, (d) empat, dan (e) lima Skenario 2 ..... 63

Gambar 4.10	Arsitektur model terbaik Replikasi (a) satu, (b) dua, (c) tiga, (d) empat, dan (e) lima Skenario 2 ..	65
Gambar 4.11	(a) <i>Time Series plot</i> data simulasi replikasi ketiga, (b) <i>Scatter plot</i> untuk komponen residual dengan lag 1, (c) <i>Box plot</i> data simulasi, dan (d) <i>Box plot</i> data simulasi tanpa tren Skenario 3.....	67
Gambar 4.12	<i>Plot ACF dan PACF Residal Regresi Time Series</i> Replikasi Tiga.....	69
Gambar 4.13	<i>Plot ACF dan PACF Residual Kuadrat Model ARIMAX</i> Replikasi Tiga.....	73
Gambar 4.14	<i>Plot PACF</i> Replikasi (a) satu, (b) dua, (c) tiga, (d) empat, dan (e) lima Skenario 3 .....	74
Gambar 4.15	Arsitektur FFNN Model Terbaik (a) satu, (b) dua, (c) tiga, (d) empat, dan (e) lima Skenario 3 ..	77
Gambar 4.16	Arsitektur Model Terbaik Replikasi (a) satu, (b) dua, (c) tiga, (d) empat, dan (e) lima Skenario 3 ..	79
Gambar 4.17	<i>Plot ACF dan PACF Residual Kuadrat Model ARIMAX</i> Replikasi Tiga.....	80
Gambar 4.18	(a) <i>Time Series plot</i> data simulasi replikasi pertama, (b) <i>Scatter plot</i> untuk komponen residual dengan lag 1, (c) <i>Box plot</i> data simulasi, dan (d) <i>Box plot</i> data simulasi tanpa tren Skenario 4.....	81
Gambar 4.19	<i>Plot ACF dan PACF Residal Regresi Time Series</i> Replikasi Tiga.....	84
Gambar 4.20	<i>Plot ACF dan PACF Residual Kuadrat Model ARIMAX</i> Replikasi Tiga.....	87
Gambar 4.21	<i>Plot PACF</i> Replikasi (a) satu, (b) dua, (c) tiga, (d) empat, dan (e) lima Skenario 4 .....	89
Gambar 4.22	Arsitektur FFNN Model Terbaik (a) satu, (b) dua, (c) tiga, (d) empat, dan (e) lima Skenario 4 ..	91
Gambar 4.23	Arsitektur Model Terbaik Replikasi (a) satu, (b) dua, (c) tiga, (d) empat, dan (e) lima Skenario 4 ..	93

Gambar 4.24	<i>Plot ACF dan PACF Residual Kuadrat Model Hybrid ARIMAX-NN Replikasi Tiga</i> .....	97
Gambar 4.25	Data Aktual Versus <i>Forecast</i> Studi Simulasi Homogen Linier Metode (a) ARIMAX, (b) NN, dan (c) <i>Hybrid ARIMAX-NN</i> .....	98
Gambar 4.26	Data Aktual Versus <i>Forecast</i> Studi Simulasi Homogen Non-Linier Metode (a) ARIMAX, (b) NN, dan (c) <i>Hybrid ARIMAX-NN</i> .....	98
Gambar 4.27	Data Aktual Versus <i>Forecast</i> Studi Simulasi Heterogen Linier Metode (a) ARIMAX, (b) NN, dan (c) <i>Hybrid ARIMAX-NN</i> .....	99
Gambar 4.28	Data Aktual Versus <i>Forecast</i> Studi Simulasi Heterogen Non- Linier Metode (a) ARIMAX, (b) NN, dan (c) <i>Hybrid ARIMAX-NN</i> .....	99
Gambar 4.29	<i>Plot Time Series</i> (a) <i>Inflow</i> dan (b) <i>Outflow</i> Uang Kartal di Kantor Perwakilan Bank Indonesia Provinsi Jawa Barat.....	100
Gambar 4.30	Diagram Batang Rata-Rata Bulanan <i>Inflow</i> dan <i>Outflow</i> (Triliun) Uang Kartal di Kantor Perwakilan Bank Indonesia Provinsi Jawa Barat .....	102
Gambar 4.31	Diagram Batang Rata-Rata (a) <i>Inflow</i> dan (b) <i>Outflow</i> Uang Kartal (Triliun) Menurut Hari Raya Idul Fitri di Kantor Perwakilan Bank Indonesia Provinsi Jawa Barat.....	103
Gambar 4.32	<i>Time Series Plot</i> (a) <i>Inflow</i> dan (b) <i>Outflow</i> Uang Kartal.....	107
Gambar 4.33	Box-Cox Data <i>Outflow</i> Uang Kartal.....	108
Gambar 4.34	<i>Plot ACF dan PACF Residal Regresi Time Series Outflow</i> .....	111
Gambar 4.35	Box-Cox Data <i>Inflow</i> Uang Kartal .....	117
Gambar 4.36	<i>Plot ACF dan PACF Residal Regresi Time Series Inflow</i> .....	119
Gambar 4.37	<i>Plot ACF dan PACF Residual Kuadrat Model ARIMAX Inflow</i> Uang Kartal .....	125

Gambar 4.38	<i>Plot PACF Outflow</i> Uang Kartal .....	126
Gambar 4.39	Arsitektur Model Terbaik <i>Neural Network Outflow</i> Uang Kartal.....	127
Gambar 4.40	<i>Plot PACF Inflow</i> Uang Kartal.....	128
Gambar 4.41	Arsitektur Model Terbaik <i>Neural Network Inflow</i> Uang Kartal .....	129
Gambar 4.42	Arsitektur Model Terbaik <i>Neural Network Residual Model ARIMAX Outflow</i> Uang Kartal .....	131
Gambar 4.43	Arsitektur Model Terbaik <i>Neural Network Residual Model ARIMAX Inflow</i> Uang Kartal	134
Gambar 4.44	Perbandingan Hasil Peramalan <i>Out-sample Model ARIMAX, NN, dan Hybrid ARIMAX-NN</i> dengan Data <i>Outflow</i> Uang Kartal.....	138
Gambar 4.45	Perbandingan Hasil Peramalan <i>Out-sample Model ARIMAX, NN, dan Hybrid ARIMAX-NN</i> dengan Data <i>Outflow</i> Uang Kartal.....	138
Gambar 4.46	Arsitektur Model Peramalan <i>Neural Network Residual</i> dari Model <i>ARIMAX Outflow</i> Uang Kartal .....	139



## DAFTAR TABEL

	Halaman
Tabel 2.1 Bentuk Transformasi Box-Cox .....	12
Tabel 2.2 Plot ACF dan PACF Model ARIMA Non-Musiman .....	14
Tabel 3.1 Tanggal Terjadinya Hari Raya Idul Fitri 2004-2016 .....	31
Tabel 4.1 Tanggal Terjadinya Hari Raya Idul Fitri 2001-2016 .....	40
Tabel 4.2 Estimasi Parameter Regresi <i>Time Series</i> Replikasi Satu .....	43
Tabel 4.3 Uji Asumsi <i>White Noise</i> Residual Regresi <i>Time Series</i> Skenario 1 .....	43
Tabel 4.4 Estimasi Parameter dan Uji signifikansi Parameter ARIMA Skenario 1 .....	45
Tabel 4.5 Uji Asumsi Independen Skenario 1 .....	45
Tabel 4.6 Akurasi Peramalan Model ARIMAX Skenario 1 ....	46
Tabel 4.7 Uji Heteroskedastisitas Model ARIMAX Skenario 1 .....	47
Tabel 4.8 Uji Terasvirta Skenario 1 .....	48
Tabel 4.9 Akurasi Peramalan Model <i>Neural Network</i> dengan Input Lag Skenario 1 .....	49
Tabel 4.10 Akurasi Peramalan Model <i>Neural Network</i> dengan Input Lag dan <i>Dummy</i> Skenario 1 .....	49
Tabel 4.11 Akurasi Peramalan Model <i>Hybrid</i> ARIMAX-NN Skenario 1 .....	51
Tabel 4.12 Uji Heteroskedastisitas Model <i>Hybrid</i> ARIMAX-NN Skenario 1 .....	53
Tabel 4.13 Estimasi Parameter Regresi <i>Time Series</i> Replikasi Satu .....	55
Tabel 4.14 Uji Asumsi <i>White Noise</i> Residual Regresi <i>Time Series</i> Skenario 2 .....	56
Tabel 4.15 Estimasi Parameter dan Uji signifikansi Parameter ARIMA Skenario 2 .....	57

Tabel 4.16	Uji Asumsi Independen Skenario 2 .....	57
Tabel 4.17	Akurasi Peramalan Model ARIMAX Skenario 2 ....	59
Tabel 4.18	Uji Heteroskedastisitas Model ARIMAX Skenario 2 .....	60
Tabel 4.19	Uji Terasvirta Skenario 2 .....	61
Tabel 4.20	Akurasi Peramalan Model <i>Neural Network</i> dengan Input Lag Skenario 2 .....	61
Tabel 4.21	Akurasi Peramalan Model <i>Neural Network</i> dengan Input Lag dan <i>Dummy</i> Skenario 2 .....	62
Tabel 4.22	Akurasi Peramalan Model <i>Hybrid</i> ARIMAX-NN Skenario 2 .....	64
Tabel 4.23	Uji Heteroskedastisitas Model <i>Hybrid</i> ARIMAX- NN Skenario 2 .....	65
Tabel 4.24	Parameter Distribusi Uniform (a.b) .....	66
Tabel 4.25	Estimasi Parameter Regresi <i>Time Series</i> Replikasi Tiga .....	68
Tabel 4.26	Uji Asumsi <i>White Noise</i> Residual Regresi <i>Time Series</i> Replikas Tiga .....	69
Tabel 4.27	Estimasi Parameter dan Uji signifikansi Parameter ARIMA Skenario 3 .....	71
Tabel 4.28	Uji Asumsi Independen Skenario 3 .....	71
Tabel 4.29	Akurasi Peramalan Model ARIMAX Skenario 1 ....	72
Tabel 4.30	Uji Heteroskedastisitas Model ARIMAX Skenario 3 .....	73
Tabel 4.31	Hasil Estimasi Parameter ARCH Model ARIMAX Skenario 3 .....	
Tabel 4.32	Uji Terasvirta Skenario 3 .....	75
Tabel 4.33	Akurasi Peramalan Model <i>Neural Network</i> dengan Input Lag Skenario 3 .....	75
Tabel 4.34	Akurasi Peramalan Model <i>Neural Network</i> dengan Input Lag dan <i>Dummy</i> Skenario 3 .....	76
Tabel 4.35	Akurasi Peramalan Model <i>Hybrid</i> ARIMAX-NN Skenario 3 .....	78
Tabel 4.36	Uji Heteroskedastisitas Model <i>Hybrid</i> ARIMAX- NN Skenario 3 .....	79

Tabel 4.37	Hasil Estimasi Parameter ARCH Model <i>Hybrid</i> ARIMAX-NN Skenario 3 .....	80
Tabel 4.38	Estimasi Parameter Regresi <i>Time Series</i> Replikasi Tiga .....	83
Tabel 4.39	Uji Asumsi <i>White Noise</i> Residual Regresi <i>Time Series</i> Skenario 4.....	83
Tabel 4.40	Estimasi Parameter dan Uji signifikansi Parameter ARIMA Skenario 4 .....	84
Tabel 4.41	Uji Asumsi Independen Skenario 4 .....	85
Tabel 4.42	Akurasi Peramalan Model ARIMAX Skenario 4 .....	86
Tabel 4.43	Uji Heteroskedastisitas Model ARIMAX Skenario 4 ..	87
Tabel 4.44	Hasil Estimasi Parameter ARCH Model ARIMAX.....	88
Tabel 4.45	Uji Terasvirta Skenario 4 .....	89
Tabel 4.46	Akurasi Peramalan Model <i>Neural Network</i> dengan Input Lag Skenario 4.....	90
Tabel 4.47	Akurasi Peramalan Model <i>Neural Network</i> dengan Input Lag dan <i>Dummy</i> Skenario 4.....	90
Tabel 4.48	Akurasi Peramalan Model <i>Hybrid</i> ARIMAX-NN Skenario 4 .....	92
Tabel 4.49	Uji Heteroskedastisitas Model <i>Hybrid</i> ARIMAX-NN Skenario 4.....	94
Tabel 4.50	Hasil Estimasi Parameter ARCH Model <i>Hybrid</i> ARIMAX-NN Skenario 4 .....	95
Tabel 4.51	Perbandingan Akurasi Peramalan .....	97
Tabel 4.52	Kebijakan Bank Indonesia.....	101
Tabel 4.53	Statistika Deskriptif <i>Inflow</i> dan <i>Outflow</i> Uang Kartal (Triliun).....	101
Tabel 4.54	Pola Dummy Variabel Dummy Kebijakan .....	107
Tabel 4.55	Estimasi Parameter Regresi <i>Time Series Outflow</i> Uang Kartal .....	109
Tabel 4.56	Uji Asumsi <i>White Noise</i> Residual Regresi <i>Time Series Outflow</i> .....	110
Tabel 4.57	Estimasi Parameter dan Uji signifikansi Parameter ...	111
Tabel 4.58	Uji Asumsi Independen.....	111

Tabel 4.59	Hasil Estimasi Parameter ARIMAX Menggunakan Semua Parameter dengan Efek Variasi Kalender <i>Outflow</i> Uang Kartal.....	113
Tabel 4.60	Hasil Estimasi Parameter ARIMAX yang Telah Signifikan dengan Efek Variasi Kalender <i>Outflow</i> Uang Kartal.....	114
Tabel 4.61	Perbandingan Hasil Ramalan Model ARIMAX Menggunakan Semua Parameter dan Memuat Parameter Signifikan <i>Outflow</i> Uang Kartal .....	115
Tabel 4.62	Perbandingan Hasil Ramalan Model ARIMAX <i>Outflow</i> .....	116
Tabel 4.63	Uji Heteroskedastisitas Model ARIMAX <i>Outflow</i>	116
Tabel 4.64	Estimasi Parameter Regresi Time Series <i>Inflow</i> Uang Kartal.....	118
Tabel 4.65	Uji Asumsi <i>White Noise</i> Residual Regresi Time Series <i>Inflow</i> .....	119
Tabel 4.66	Estimasi Parameter dan Uji signifikansi Parameter ARIMA.....	119
Tabel 4.67	Uji Asumsi Independen .....	120
Tabel 4.68	Estimasi Parameter ARIMAX $([3],0,0)(0,0,1)^{24}$ dengan Semua Parameter dengan Efek Variasi Kalender <i>Inflow</i> Uang Kartal .....	120
Tabel 4.69	Hasil Estimasi Parameter ARIMAX yang Telah Signifikan dengan Efek Variasi Kalender <i>Inflow</i> Uang Kartal.....	122
Tabel 4.70	Perbandingan Hasil Ramalan Model ARIMAX Menggunakan Semua Parameter dan Memuat Parameter Signifikan Pada <i>Inflow</i> Uang Kartal .....	123
Tabel 4.71	Perbandingan Hasil Ramalan Model ARIMAX <i>Inflow</i> .....	124
Tabel 4.72	Uji Heteroskedastisitas Model ARIMAX <i>Inflow</i> ...	125
Tabel 4.73	Hasil Estimasi Parameter ARCH.....	125
Tabel 4.74	Akurasi Peramalan Model <i>Neural Network Outflow</i> .....	127
Tabel 4.75	Akurasi Peramalan Model <i>Neural Network Inflow</i>	128

Tabel 4.76	Uji Asumsi Independen.....	130
Tabel 4.77	Uji Heteroskedastisitas Model <i>Hybrid</i> ARIMAX- NN.....	132
Tabel 4.78	Akurasi Peramalan Model <i>Hybrid</i> ARIMAX-NN <i>Inflow</i> .....	133
Tabel 4.79	Uji Heteroskedastisitas Model <i>Hybrid</i> ARIMAX- NN.....	134
Tabel 4.80	Hasil Perbandingan RMSE <i>Outflow</i> dan <i>Inflow</i> Uang Kartal.....	135
Tabel 4.81	Hasil Rasio <i>Benchmark Inflow</i> dan <i>Outflow</i> .....	135
Tabel 4.82	Hasil Perbandingan RMSE Adaptif <i>Outflow</i> Uang Kartal Pada Metode ARIMAX, NN, dan <i>Hybrid</i> ARIMAX-NN .....	136
Tabel 4.83	Hasil Perbandingan RMSE Adaptif <i>Inflow</i> Uang Kartal Pada Metode ARIMAX, NN, dan <i>Hybrid</i> ARIMAX-NN .....	136
Tabel 4.84	Nilai Ramalan <i>Inflow</i> dan <i>Outflow</i> Periode Januari-Desember Tahun 2017 (dalam Triliun).....	138

*Halaman ini sengaja dikosongkan*

## DAFTAR LAMPIRAN

	<b>Halaman</b>
Lampiran 1 Data <i>Outflow</i> dan <i>Inflow</i> di Provinsi Jawa Barat Periode Januari 2004-Desember 2016 .....	147
Lampiran 2 Syntax Program SAS untuk Regresi <i>Time Series</i> ..	148
Lampiran 3 Syntax Program SAS untuk ARIMAX.....	149
Lampiran 4 Syntax Program SAS untuk ARIMA.....	150
Lampiran 5 Syntax Program R untuk <i>Neural Network</i> .....	151
Lampiran 6 <i>Time Series Plot</i> Skenario 1 .....	152
Lampiran 7 <i>Time Series Plot</i> Skenario 2.....	153
Lampiran 8 <i>Time Series Plot</i> Skenario 3.....	154
Lampiran 9 <i>Time Series Plot</i> Skenario 4.....	155
Lampiran 10 Pemodelan ARIMAX Skenario 1 untuk Replikasi 1 .....	156
Lampiran 11 Pemodelan ARIMAX Skenario 1 untuk Replikasi 2 .....	157
Lampiran 12 Pemodelan ARIMAX Skenario 1 untuk Replikasi 3 .....	158
Lampiran 13 Pemodelan ARIMAX Skenario 1 untuk Replikasi 4 .....	159
Lampiran 14 Pemodelan ARIMAX Skenario 1 untuk Replikasi 5 .....	160
Lampiran 15 Pemodelan ARIMAX Skenario 2 untuk Replikasi <sup>31</sup> .....	161
Lampiran 16 Pemodelan ARIMAX Skenario 2 untuk Replikasi 2 .....	162
Lampiran 17 Pemodelan ARIMAX Skenario 2 untuk Replikasi 3 .....	163
Lampiran 18 Pemodelan ARIMAX Skenario 2 untuk Replikasi 4 .....	164

Lampiran 19	Pemodelan ARIMAX Skenario 2 untuk Replikasi 5 .....	165
Lampiran 20	Pemodelan ARIMAX Skenario 3 untuk Replikasi 1 .....	166
Lampiran 21	Pemodelan ARIMAX Skenario 3 untuk Replikasi 2 .....	167
Lampiran 22	Pemodelan ARIMAX Skenario 3 untuk Replikasi 3 .....	168
Lampiran 23	Pemodelan ARIMAX Skenario 3 untuk Replikasi 4 .....	169
Lampiran 24	Pemodelan ARIMAX Skenario 3 untuk Replikasi 5 .....	170
Lampiran 25	Pemodelan ARIMAX Skenario 4 untuk Replikasi 1 .....	171
Lampiran 26	Pemodelan ARIMAX Skenario 4 untuk Replikasi 2 .....	172
Lampiran 27	Pemodelan ARIMAX Skenario 4 untuk Replikasi 3 .....	173
Lampiran 28	Pemodelan ARIMAX Skenario 4 untuk Replikasi 4 .....	174
Lampiran 29	Pemodelan ARIMAX Skenario 4 untuk Replikasi 5 .....	175
Lampiran 30	Pemodelan Regresi <i>Time Series Outflow</i> Uang Kartal .....	176
Lampiran 31	Pemodelan ARIMA $([2],0,[1,13])(1,0,0)^{12}$ <i>Outflow</i> Uang Kartal.....	177
Lampiran 32	Pemodelan ARIMA $([2],0,[1,13])(0,0,1)^{12}$ <i>Outflow</i> Uang Kartal.....	178
Lampiran 33	Pemodelan ARIMA $([1,2,13,14],0,0)(1,0,0)^{12}$ <i>Outflow</i> Uang Kartal.....	179



Lampiran 34	Pemodelan ARIMA $(1,0,[13])(0,0,1)^{12}$ <i>Outflow</i> Uang Kartal.....	180
Lampiran 35	Pemodelan ARIMAX ke-1 <i>Outflow</i> Uang Kartal (Semua Parameter) .....	181
Lampiran 36	Pemodelan ARIMAX ke-2 <i>Outflow</i> Uang Kartal (Semua Parameter) .....	182
Lampiran 37	Pemodelan ARIMAX ke-3 <i>Outflow</i> Uang Kartal (Semua Parameter) .....	183
Lampiran 38	Pemodelan ARIMAX ke-4 <i>Outflow</i> Uang Kartal (Semua Parameter) .....	184
Lampiran 39	Pemodelan ARIMAX ke-1 <i>Outflow</i> Uang Kartal (Parameter Signifikan).....	185
Lampiran 40	Pemodelan ARIMAX ke-2 <i>Outflow</i> Uang Kartal (Parameter Signifikan).....	186
Lampiran 41	Pemodelan ARIMAX ke-3 <i>Outflow</i> Uang Kartal (Parameter Signifikan).....	187
Lampiran 42	Pemodelan ARIMAX ke-4 <i>Outflow</i> Uang Kartal (Parameter Signifikan).....	188
Lampiran 43	Pemodelan Regresi <i>Time Series Inflow</i> Uang Kartal .....	189
Lampiran 44	Pemodelan ARIMA $([3],0,0) (0,0,1)^{24}$ <i>Inflow</i> Uang Kartal.....	190
Lampiran 45	Pemodelan ARIMA $(0,0,[3,16])(1,0,0)^{24}$ <i>Inflow</i> Uang Kartal.....	191
Lampiran 46	Pemodelan ARIMAX ke-1 <i>Inflow</i> Uang Kartal (Semua Parameter) .....	192
Lampiran 47	Pemodelan ARIMAX ke-2 <i>Inflow</i> Uang Kartal (Semua Parameter) .....	193
Lampiran 48	Pemodelan ARIMAX ke-1 <i>Inflow</i> Uang Kartal (Parameter Signifikan).....	194

Lampiran 49	Pemodelan ARIMAX ke-2 <i>Inflow</i> Uang Kartal (Parameter Signifikan).....	195
Lampiran 50	Pemodelan Ramalan ARIMAX <i>Outflow</i> Uang Kartal 12 Bulan Kedepan .....	196
Lampiran 51	Pemodelan Ramalan ARIMAX <i>Inflow</i> Uang Kartal 12 Bulan Kedepan) .....	197
Lampiran 52	Surat Keterangan Data Instansi .....	198

## **BAB I**

### **PENDAHULUAN**

#### **1.1 Latar Belakang**

Uang adalah alat pembayaran yang sah di Indonesia sebagai alat transaksi ekonomi, uang juga bisa diartikan segala sesuatu yang siap sedia dan pada umumnya diterima dalam pembayaran pembelian barang, jasa dan untuk membayar hutang (Thomas, 1974). Jumlah uang yang beredar terdiri dari uang kartal dan uang giral. Uang kartal terdiri dari dua jenis yaitu uang kertas dan logam. Uang kartal memiliki fungsi sebagai alat penukar atau alat pembayaran serta salah satu alat utama perekonomian suatu negara yang memegang peranan penting, dimana pada umumnya masyarakat masih menggunakan uang kartal untuk keperluan transaksi ekonomi. Oleh karena itu, peredaran uang yang baik sangat diperlukan untuk menunjang perekonomian suatu negara.

Menurut Undang-Undang Republik Indonesia Nomor 6 Tahun 2009, Bank Indonesia menjadi Bank sentral yang independen dalam melaksanakan tugas dan wewenangnya. Salah satu tugas Bank Indonesia adalah mengatur dan menjaga sistem pembayaran. Bank Indonesia merupakan satu-satunya lembaga yang berwenang untuk mengeluarkan dan mengedarkan, menarik dan memusnahkan uang dari peredaran. Terkait dengan peran Bank Indonesia dalam mengeluarkan dan mengedarkan uang, Bank Indonesia senantiasa berupaya untuk dapat memenuhi kebutuhan uang kartal di masyarakat baik dalam nominal yang cukup, jenis pecahan yang sesuai, tepat waktu, dan dalam kondisi yang layak edar (Bank Indonesia, 2013). Sebagai salah satu likuiditas perbankan, Bank Indonesia melalui *Open Market Committee* (OMC) memiliki agenda bulanan dalam melakukan proyeksi uang kartal yang diedarkan. Uang kartal yang diedarkan merupakan uang kartal yang ada di masyarakat serta uang kartal yang disimpan sebagai kas Bank Umum. Aliran uang kartal yang masuk ke Bank Indonesia melalui kegiatan setoran yang dilakukan oleh Bank Umum disebut *inflow*, sedangkan *outflow* adalah aliran uang kartal

yang keluar dari Bank Indonesia melalui kegiatan penarikan uang tunai atau pembayaran tunai melalui Bank Umum. (Wulansari *et al.*, 2014)

Seiring dengan pertumbuhan transaksi ekonomi Indonesia, perkembangan *inflow* dan *outflow* Kantor Perwakilan Bank Indonesia Jawa Barat menunjukkan tren peningkatan dari tahun ke tahunnya. Menurut Yukha (2015) menyatakan penyebaran *inflow* pada periode Desember 2014, Jawa Barat merupakan wilayah dengan jumlah *inflow* yang tertinggi yaitu 20,05%, disusul Kantor Pusat sebesar 18,37%, serta Jawa Tengah dan Daerah Istimewa Yogyakarta sebesar 14,82%. Selain itu, berdasarkan data historis tahun 2011 hingga 2015 Jawa Barat mengalami kondisi yang *net inflow*. Hal itu dikonfirmasi oleh Kepala Perwakilan Bank Indonesia Jawa Barat, bahwa perputaran kas pada tahun 2015 mengalami *net inflow* sebesar Rp35,4 triliun, artinya jumlah uang yang masuk ke Jawa Barat lebih besar dibandingkan dengan jumlah uang yang keluar. Hal itu dipengaruhi oleh kondisi Jawa Barat yang merupakan salah satu pusat perindustrian dan perdagangan serta banyaknya obyek wisata yang banyak dikunjungi wisatawan, terutama pada periode akhir tahun. Oleh karena itu, penelitian tentang peramalan serta pemodelan *inflow* dan *outflow* di Jawa Barat dipandang perlu untuk mengatur aliran uang kartal yang masuk dan keluar.

Penelitian sebelumnya tentang peramalan uang kartal pernah dilakukan oleh Karomah dan Suhartono (2014) menggunakan model variasi kalender dan model *Autoregressive Distributed Lag* (ARDL) dengan variabel ekonomi makro yaitu suku bunga Sertifikat Bank Indonesia (SBI), kurs rupiah terhadap dollar AS, dan Indeks Harga Konsumen (IHK), diperoleh hasil bahwa Idul Fitri serta IHK berpengaruh signifikan terhadap *netflow* uang kartal. Model terbaik yang didapatkan adalah model gabungan antara variasi kalender berbasis ARIMAX dan model ARDL berbasis *time series*.

Yukha (2015) melakukan penelitian tentang penerapan hirarki menggunakan variasi kalender untuk peramalan *inflow* dan *outflow*

uang kartal di Jawa Barat. Berdasarkan penelitian Yukha, didapatkan bahwa karakteristik *inflow* dan *outflow* di Jawa Barat periode Januari 2003 hingga Desember 2014 mempunyai pola musiman yang dipengaruhi oleh hari raya Idul Fitri. Model terbaik untuk data *inflow* di KPw BI Bandung, Tasikmalaya, dan Jawa Barat menggunakan ARIMAX sedangkan KPw BI Cirebon menggunakan *time series regression* namun untuk model terbaik data *outflow* di semua kantor perwakilan menggunakan metode ARIMAX. Selain itu di tahun yang sama, Wulansari dan Suhartono (2015) melakukan peramalan tentang *netflow* uang kartal menggunakan metode ARIMAX dan *Neural Network* (RBFN) studi kasus di Bank Indonesia, hasil penelitian menunjukkan bahwa variasi kalender dan variabel IHK berpengaruh signifikan terhadap *netflow*. Model terbaik yang didapatkan adalah model ARIMAX dengan efek variasi kalender serta variabel prediktor IHK.

Uraian di atas, menunjukkan bahwa terdapat beberapa metode *time series* yang dapat digunakan dalam peramalan *inflow* dan *outflow*. Secara umum, terdapat tiga pendekatan yang digunakan yaitu model peramalan linier, model peramalan non-linier, dan model gabungan (*hybrid*). Pada penelitian ini, model peramalan linier yang digunakan adalah model ARIMAX, untuk model non-linier yang digunakan adalah *Neural Network* (NN) serta model gabungan yang digunakan adalah *hybrid* ARIMAX-NN. Model ARIMAX merupakan model ARIMA yang diberi tambahan variabel prediktor, misalnya variabel *dummy* untuk variasi kalender dan tren deterministik. Salah satu peneliti pertama yang mempelajari efek variasi hari libur dengan identifikasi dan estimasi model ARIMA yaitu Liu (1980) menyarankan untuk memodifikasi model ARIMA dengan menyertakan informasi hari libur sebagai variabel input deterministik. Menurut penelitian Yukha (2015) *inflow* dan *outflow* Provinsi Jawa Barat dipengaruhi oleh pola musiman, *trend*, serta efek variasi kalender hari raya Idul Fitri. Efek hari raya Idul Fitri memberikan pengaruh yang signifikan terhadap aliran uang kartal. Hal ini disebabkan karena hari raya

Idul Fitri tidak mengikuti kalender masehi, namun mengikuti kalender hijriyah. Oleh karena itu, pada penelitian ini melibatkan variabel *dummy* hari raya Idul Fitri sebagai variabel prediktornya.

Pada fenomena *real*, data *time series* seperti data keuangan biasanya bersifat non-linier. *Artifisial Neural Network* (ANN) atau biasa dikenal dengan *Neural Network* (NN) sering digunakan untuk pemodelan non-linier. Aplikasi jaringan syaraf tiruan ini sudah banyak diaplikasikan ke banyak kasus seperti pengenalan pola, *signal processing*, dan peramalan. Pada kasus peramalan, NN meramalkan berdasarkan pola kejadian yang ada di masa lampau dikarenakan NN dapat mengingat dan membuat generalisasi dari apa yang sudah ada sebelumnya. Beberapa penelitian menggunakan metode NN yang pernah dilakukan oleh Febrina, Arina, dan Ekawati (2013) tentang peramalan jumlah permintaan produksi menggunakan jaringan syaraf tiruan *backpropagation*. Peneliti lainnya dilakukan oleh Pakaja, Naba, dan Purwanto (2012) meramalkan penjualan mobil menggunakan jaringan syaraf tiruan dan *Certainty Factor*.

Menurut Manajer Tim Data Statistik Ekonomi dan Keuangan Daerah (TDSEKD) Bank Indonesia Jawa Barat, menunjukkan fakta bahwa metode yang biasa digunakan untuk peramalan *inflow* dan *outflow* yaitu ekstrapolasi data dan ARIMA terkadang kurang memuaskan. Hal tersebut dikarenakan jauh dari nilai aktual *inflow* dan *outflow*, sehingga diperlukan per-baikan metode peramalan maupun pengembangan model peramalan. Salah satu pengembangan model untuk peramalan *inflow* dan *outflow* yaitu dengan menggunakan model *hybrid*. Model *hybrid* digunakan karena pada kasus data deret waktu jarang ditemukan data yang mengandung pola linier atau pola non-linier saja namun sering didapatkan gabungan pola linier dan pola non-linier. Zhang (2003) memperkenalkan model gabungan hasil kombinasi model linier ARIMA dengan level satu dan model non-linier *neural network* pada level dua. Penelitian sebelumnya menggunakan metode *hybrid*, Hadi (2016) melakukan penelitian pemodelan *hybrid* ARIMAX-NN dan GARCH untuk peramalan *inflow* dan *outflow*

uang kartal. Penelitian lainnya dilakukan oleh Paembonan (2016) tentang ARIMAX, *Radial Basis Function*, dan *hybrid* ARIMAX-RBFN untuk peramalan *inflow* dan *outflow* uang kartal di Provinsi Papua.

Pada umumnya, pemodelan data deret waktu dilakukan dengan asumsi varians residual yang konstan dari waktu ke waktu. Namun pada kenyataannya, banyak data deret waktu yang mempunyai varians residual tidak konstan, khususnya pada bidang keuangan. Hal ini menyebabkan pemodelan dengan menggunakan analisis deret waktu yang mempunyai asumsi homoskedastisitas tidak dapat digunakan. Model yang tepat untuk menganalisis perilaku seperti ini disebut dengan *Autoregressive Conditional Heteroscedacity* (ARCH). Model tersebut memperbolehkan adanya asumsi heteroskedastisitas yang pertama kali dikenalkan oleh Engle (1982). Model ARCH diaplikasikan untuk memodelkan inflasi di Inggris periode Februari 1952 hingga Februari 1977. Kemudian di tahun 1986, peneliti bernama Bollerslev mengembangkan model ARCH menjadi model *Generalized Autoregressive Conditional Heteroscedacity* (GARCH) dengan memasukan varians residual di masa lalu. Penelitian menggunakan model ARCH atau GARCH pernah dilakukan oleh Xiaojun (2009) memodelkan pasar saham di China menggunakan model Multivariat GARCH kemudian tahun 2011, Edward memodelkan Inflasi di Tanzania menggunakan GARCH. Selain itu, Widasari dan Wahyuningsih (2012) mengaplikasikan model ARCH dan GARCH dalam peramalan tingkat inflasi di Indonesia.

Pada dekade terakhir ini, meningkatkan akurasi dalam peramalan dapat dilakukan dengan mengembangkan model peramalan gabungan atau *hybrid* yang menunjukkan akurasi lebih baik jika dibandingkan dengan peramalan tunggal (Schumacher, 2011; Bradley & Schwartz, 2011). Hal ini juga didukung oleh hasil, kesimpulan, dan implikasi dari *The M3-Competition* (Makridakis & Hibon, 2000), bahwa kombinasi dari metode individu yang menggabungkan beberapa model peramalan akan meningkatkan

akurasi ramalan. Fakta itulah yang melandasi dilakukan penelitian model gabungan (*hybrid*).

## 1.2 Rumusan Masalah

Berdasarkan data historinya, Jawa Barat selalu mengalami kondisi *net inflow* namun untuk aliran *inflow* dan *outflow* setiap bulannya mengalami fluktuatif sehingga Pemodelan dan peramalan untuk *inflow* dan *outflow* Jawa Barat dipandang sangat diperlukan untuk membuat perencanaan pengadaan aliran uang kartal yang masuk dan keluar dengan tepat. Namun sebelum menganalisis data *real*, akan dilakukan analisis terhadap data simulasi yang mengandung pola tren, musiman, dan variasi kalender. Rumusan masalah pada penelitian ini adalah sebagai berikut :

1. Bagaimana metode terbaik untuk menganalisis studi simulasi yang mengandung pola tren, musiman, dan variasi kalender menggunakan ARIMAX, *Neural Network*, *Hybrid ARIMAX-NN* dan GARCH?
2. Bagaimana karakteristik data *inflow* dan *outflow* uang kartal pada Kantor Perwakilan Bank Indonesia Provinsi Jawa Barat?
3. Bagaimana model yang tepat untuk meramalkan *inflow* dan *outflow* uang kartal di Kantor Perwakilan Bank Indonesia Provinsi Jawa Barat dengan menggunakan ARIMAX, *Neural Network*, *Hybrid ARIMAX-NN* dan GARCH?
4. Bagaimana perbandingan performa model yang tepat untuk meramalkan *inflow* dan *outflow* uang kartal di Kantor Perwakilan Bank Indonesia Provinsi Jawa Barat dengan menggunakan ARIMAX, *Neural Network*, *Hybrid ARIMAX-NN* dan GARCH?

## 1.3 Tujuan Penelitian

Tujuan dari penelitian ini adalah sebagai berikut :

1. Mengetahui metode terbaik untuk studi simulasi yang mengandung pola tren, musiman, dan variasi kalender



kalender menggunakan ARIMAX, *Neural Network*, *Hybrid ARIMAX-NN* dan GARCH

2. Mendeskripsikan karakteristik data *inflow* dan *outflow* pada Kantor Perwakilan Bank Indonesia Provinsi Jawa Barat
3. Mendapatkan model yang tepat pada data *inflow* dan *outflow* di Kantor Perwakilan Bank Indonesia Provinsi Jawa Barat dengan menggunakan ARIMAX, *Neural Network*, dan *Hybrid ARIMAX-NN* dan GARCH
4. Membandingkan hasil peramalan *inflow* dan *outflow* di Kantor Perwakilan Bank Indonesia Provinsi Jawa Barat dengan menggunakan ARIMAX, *Neural Network*, *Hybrid ARIMAX-NN* dan GARCH

#### **1.4 Manfaat Penelitian**

Manfaat dari penelitian ini adalah sebagai berikut :

1. Membantu Bank Indonesia dengan mendapatkan metode dan model peramalan yang tepat pada *inflow* dan *outflow* uang kartal di Kantor Perwakilan Bank Indonesia Provinsi Jawa Barat sehingga bisa membuat kebijakan-kebijakan untuk pengadaan uang kartal.
2. Mengembangkan wawasan dan pengetahuan mengenai model ARIMAX, *Neural Network*, *Hybrid ARIMAX-NN* dan GARCH

#### **1.5 Batasan Masalah**

Batasan masalah yang digunakan dalam penelitian ini adalah data *inflow* dan *outflow* uang kartal periode Januari 2004 hingga Desember 2016 di KPw BI Provinsi Jawa Barat. Model linier yang digunakan adalah ARIMAX, model non-linier yang digunakan adalah NN, dan model gabungan yang digunakan adalah *Hybrid ARIMAX-NN* dan GARCH.

*Halaman ini sengaja dikosongkan*

## BAB II

### TINJAUAN PUSTAKA

#### 2.1 Analisis *Time Series*

*Time Series* atau deret waktu merupakan serangkaian pengamatan terhadap suatu variabel yang diambil dari waktu ke waktu dan dicatat secara berurutan menurut urutan waktu kejadiannya dengan interval waktu tetap. Tujuan mempelajari *time series* adalah pemahaman dan gambaran untuk mengenai kondisi dan peramalan nilai masa depan serta optimalisasi sistem kontrol (Wei, 2006: 1). Metode *time series* yang digunakan untuk penelitian ini adalah ARIMAX berbasis variasi kalender, *Neural Network*, dan *Hybrid ARIMAX-NN*.

#### 2.2 Model *Autoregressive Moving Average (ARIMA)*

Model *Autoregressive Integrated Moving Average (ARIMA)* merupakan gabungan dari model AR dan MA serta adanya proses *differencing*. Penjelasan model ARIMA terdiri dari sebagai berikut

##### 1. Model *Autoregressive (AR)*

Model *Autoregressive (AR)* menjelaskan sebuah proses  $Z_t$  yang berhubungan dengan nilai  $Z$  pada waktu  $t$  sebelumnya ( $Z_{t-k}$ ) ditambah sebuah nilai residual ( $a_t$ ). Model AR adalah sebagai berikut :

$$\dot{Z}_t = \phi_1 \dot{Z}_{t-1} + \dots + \phi_p \dot{Z}_{t-p} + a_t,$$

atau

$$\phi_p(B)\dot{Z}_t = a_t. \quad (2.1)$$

dimana  $\phi_p(B) = (1 - \phi_1 B - \phi_2 B^2 - \dots - \phi_p B^p)$  dan  $\dot{Z}_t = Z_t - \mu$  serta  $a_t$  adalah sebuah residual yang sudah memenuhi asumsi *white noise* yaitu  $E(a_t) = 0$  dan  $var(a_t) = \sigma_a^2$ . (Wei, 2006: 33)

## 2. Model *Moving Average* (MA)

*Moving Average* (MA) merepresentasikan sebuah proses  $Z_t$  dengan nilai residual  $a_t$  pada waktu  $t$  sebelumnya.

Model *Moving Average* adalah sebagai berikut :

$$\dot{Z}_t = a_t - \theta_1 a_{t-1} - \theta_2 a_{t-2} - \dots - \theta_q a_{t-q},$$

atau

$$\dot{Z}_t = \theta_q(B) a_t. \quad (2.2)$$

dimana  $\theta_q(B) = (1 - \theta_1 B - \theta_2 B^2 - \dots - \theta_q B^q)$  dan  $\dot{Z}_t = Z_t - \mu$  serta  $a_t$  adalah sebuah residual yang sudah memenuhi asumsi *white noise*. (Wei, 2006: 47)

## 3. Model *Autoregressive Moving Average* (ARMA)

Jumlah parameter yang banyak akan bisa mereduksi efisiensi dalam estimasi, untuk membentuk model diperlukan AR dan MA yang dapat dituliskan sebagai berikut :

$$\dot{Z}_t = \phi_1 \dot{Z}_{t-1} + \dots + \phi_p \dot{Z}_{t-p} + a_t - \theta_1 a_{t-1} - \dots - \theta_q a_{t-q},$$

atau

$$\phi_p(B) \dot{Z}_t = \theta_q(B) a_t. \quad (2.3)$$

$\phi_p(B) = (1 - \phi_1 B - \dots - \phi_p B^p)$  dan  $\theta_q(B) = (1 - \theta_1 B - \dots - \theta_q B^q)$  serta  $a_t$  adalah sebuah residual yang sudah memenuhi asumsi *white noise*. (Wei, 2006:57)

## 4. Model *Autoregressive Integrated Moving Average* (ARIMA)

Persamaan umum dari model ARIMA  $(p, d, q)$  adalah sebagai berikut : (Wei, 2006: 72)

$$\phi_p(B)(1-B)^d Z_t = \theta_q(B) a_t, \quad (2.4)$$

dengan

$(p, d, q)$  : orde non-musiman untuk orde AR  $(p)$ , orde *differencing*  $(d)$ , orde MA  $(q)$

$\phi_p(B)$  : koefisien komponen AR non-musiman orde  $p$ , penjelasannya adalah :  $\phi_p(B) = (1 - \phi_1 B - \dots - \phi_p B^p)$

$\theta_q(B)$  : koefisien komponen MA non-musiman dengan orde  $q$ , penjelasannya adalah  $\theta_q(B) = (1 - \theta_1 B - \dots - \theta_q B^q)$

$a_t$  : nilai residual pada waktu ke- $t$  yang sudah memenuhi asumsi *white noise*.

##### 5. Model *Autoregressive Integrated Moving Average* (ARIMA) Musiman

Secara umum, berikut model ARIMA dengan efek musiman pada waktu ke  $S$  adalah ARIMA  $(P, D, Q)^s$  (Wei, 2006: 166).

$$\Phi_p(B^s)\phi_p(B)(1-B)^d(1-B^s)^D\dot{Z}_t = \theta_q(B)\Theta_Q(B^s)a_t, \quad (2.5)$$

dengan,

$(p, d, q)$  : orde AR ( $p$ ), orde *differencing* ( $d$ ), orde MA ( $q$ ) untuk pola data non-musiman

$(P, D, Q)^s$  : orde AR ( $P$ ), orde *differencing* ( $D$ ), orde MA ( $Q$ ) untuk pola data musiman

$\phi_p(B)$  : koefisien komponen AR non-musiman orde  $p$ , penjelasannya adalah :  $\phi_p(B) = (1 - \phi_1 B - \dots - \phi_p B^p)$

$\Phi_p(B^s)$  : koefisien komponen AR musiman  $s$  dengan penjelasannya adalah :

$$\Phi_p(B^s) = (1 - \Phi_1 B^s - \Phi_2 B^{2s} - \dots - \Phi_p B^{ps})$$

$\theta_q(B)$  : koefisien komponen MA non-musiman orde  $q$ , penjelasannya  $\theta_q(B) = (1 - \theta_1 B - \theta_2 B^2 - \dots - \theta_q B^q)$

$\Theta_Q(B^s)$  : koefisien komponen MA musiman  $s$  dengan penjelasannya adalah

$$\Theta_Q(B^s) = (1 - \Theta_1 B^s - \Theta_2 B^{2s} - \dots - \Theta_Q B^{Qs})$$

$(1-B)^d$  : *differencing* untuk non-musiman orde  $d$

$(1-B^s)^D$  : *differencing* untuk musiman  $s$  orde  $D$

$a_t$  : nilai residual pada waktu ke- $t$

Prosedur pembentukan model ARIMA yang sering digunakan adalah prosedur Box-Jenkins. Tahapan prosedur Box-Jenkins diantaranya identifikasi model, estimasi parameter, cek diagnosa dan peramalan.

### 2.2.1 Identifikasi Model ARIMA

Langkah pertama yang dilakukan pada identifikasi model ARIMA adalah mengetahui kestasioneran data dengan melihat plot *time series*, ACF, ataupun PACF. Kestasioneran data merupakan hal penting untuk memenuhi asumsi yang harus dipenuhi dalam *time series*. Stasioner *time series* merupakan suatu keadaan atau kondisi dimana terjadi fluktuasi data berada disekitar nilai rata-rata dan varians yang konstan. Suatu data dikatakan stasioner apabila stasioner terhadap mean dan varians. Jika data tersebut tidak stasioner dalam mean maka perlu dilakukan proses *differencing*. Proses *differencing* untuk orde ke- $d$  ditulis sebagai berikut :

$$\Delta^d Z_t = (1 - B)^d Z_t. \quad (2.6)$$

Jika data tersebut tidak stasioner dalam varians maka perlu dilakukan transformasi *Box-Cox*. Berikut persamaan transformasi *Box-Cox* dan bentuk transformasi Box- Tabel 2.1 (Wei, 2006: 85)

$$T(Z_t) = \frac{Z_t^\lambda - 1}{\lambda}. \quad (2.7)$$

**Tabel 2.1** Bentuk Transformasi Box-Cox

Nilai Estimasi $\hat{\lambda}$	Transformasi
-1,0	$\frac{1}{Z_t}$
-0,5	$\frac{1}{\sqrt{Z_t}}$
0,0	$\ln Z_t$
0,5	$\sqrt{Z_t}$
1,0	$Z_t$ (tidak ada transformasi)

### a. Autocorrelation Function (ACF)

*Autocorrelation Function* (ACF) merupakan suatu fungsi yang digunakan untuk menjelaskan hubungan linier antara  $Z_t$  dengan  $Z_{t-k}$ . Untuk melihat stasioneritas biasanya menggunakan plot ACF. Suatu proses stasioner dari  $\{Z_t\}$ , apabila  $E(Z_t) = \mu$  serta  $var(Z_t) = E(Z_t - \mu)^2 = \sigma^2$ , dimana nilai mean dan varians konstan. Berikut rumus kovarian dan korelasi  $Z_t$  dengan  $Z_{t-k}$  (Wei, 2006: 10-11)

$$\gamma_k = cov(Z_t, Z_{t-k}) = E(Z_t - \mu)(Z_{t-k} - \mu) \quad (2.8)$$

dan

$$\rho_k = \frac{cov(Z_t, Z_{t-k})}{\sqrt{var(Z_t)}\sqrt{var(Z_{t-k})}} = \frac{\gamma_k}{\gamma_0}, \quad (2.9)$$

dengan,

- $\rho_k$  : autokorelasi pada lag ke- $k$
- $\gamma_k$  : nilai kovarian  $Z_t$  dengan  $Z_{t-k}$
- $\gamma_0$  :  $var(Z_t) = var(Z_{t-k})$ .

Fungsi *Autocorrelation Function* (ACF) dan *Autocovarian* dalam proses stasioner harus memenuhi syarat sebagai berikut :

1.  $\gamma_0 = var(Z_t)$  ;  $\rho_0 = 1$
2.  $|\gamma_k| \leq \gamma_0$  ;  $|\rho_k| \leq 1$
3.  $\gamma_k = \gamma_{-k}$  dan  $\rho_k = \rho_{-k}$

Menurut Wei (2006: 22) fungsi *Autocorrelation Function* (ACF) pada sampel data deret waktu sebagai berikut :

$$\hat{\rho}_k = \frac{\sum_{t=k+1}^n (Z_t - \bar{Z})(Z_{t-k} - \bar{Z})}{\sum_{t=1}^n (Z_t - \bar{Z})^2} = \frac{\hat{\gamma}_k}{\hat{\gamma}_0}. \quad (2.10)$$

### b. *Partial Autocorrelation Function (PACF)*

*Partial Autocorrelation Function (PACF)* digunakan untuk mengukur korelasi antara  $Z_t$  dengan  $Z_{t-k}$  setelah pengaruh variabel  $Z_{t-1}, Z_{t-2}, \dots, Z_{t-k+1}$  dihilangkan. Rumus PACF dinyatakan dalam persamaan berikut: (Wei, 2006: 22)

$$\hat{\phi}_{k+1,k+1} = \frac{\hat{\rho}_{k+1} - \sum_{j=1}^k \hat{\phi}_{kj} \hat{\rho}_{k+1-j}}{1 - \sum_{j=1}^k \hat{\phi}_{kj} \hat{\rho}_j}, \quad (2.11)$$

dan

$$\hat{\phi}_{k+1,j} = \hat{\phi}_{kj} - \hat{\phi}_{k+1,k+1} \hat{\phi}_{k,k+1-j}. \quad (2.12)$$

Identifikasi model ARIMA bisa dilihat dengan menggunakan plot ACF dan PACF, dimana plot ACF untuk menentukan orde  $p$  dan plot PACF untuk menentukan orde  $q$ . Berikut bentuk-bentuk plot ACF dan PACF dari model ARIMA pada tabel 2.2 (Wei, 2006: 109)

**Tabel 2.2** Plot ACF dan PACF Model ARIMA Non Musiman

Model	Plot ACF	Plot PACF
AR( $p$ )	Turun cepat secara eksponensial ( <i>dies down</i> )	Terpotong setelah lag ke- $p$
MA( $q$ )	Terpotong setelah lag ke- $q$	Turun cepat secara eksponensial ( <i>dies down</i> )
ARMA( $p,q$ )	Turun cepat setelah lag ( $q-p$ )	Turun cepat setelah lag ( $p-q$ )

#### 2.2.2 Estimasi Parameter

Setelah dilakukan identifikasi model, tahapan selanjutnya adalah melakukan estimasi parameter dan pengujian parameter. Estimasi parameter bisa menggunakan beberapa metode yaitu metode momen, *Least Square Estimation*, dan *Maximum Likelihood Estimation* (MLE). Metode estimasi parameter yang biasa digunakan adalah *Conditional Least Square* (CLS). Metode CLS untuk model AR (1) dinyatakan sebagai berikut : (Cryer & Chan, 2008: 154-155)



$$Z_t - \mu = \phi(Z_{t-1} - \mu) + a_t, \quad (2.13)$$

dan *Sum Square Error* (SSE),

$$S(\phi, \mu) = \sum_{t=2}^n a_t^2 = \sum_{t=2}^n [(Z_t - \mu) - \phi(Z_{t-1} - \mu)]^2, \quad (2.14)$$

Setelah itu, estimasi  $\phi$  dan  $\mu$  dilakukan penurunan fungsi  $S(\phi, \mu)$  terhadap  $\mu$  dan  $\phi$ , kemudian disamakan dengan nol  $\partial S / \partial \mu = 0$  sehingga

$$\frac{\partial S}{\partial \mu} = \sum_{t=2}^n 2[(Z_t - \hat{\mu}) - \phi(Z_{t-1} - \hat{\mu})](-1 + \phi) = 0, \quad (2.15)$$

atau disederhanakan untuk  $\mu$

$$\hat{\mu} = \frac{1}{(n-1)(1-\phi)} \left[ \sum_{t=2}^n Z_t - \phi \sum_{t=2}^n Z_{t-1} \right], \quad (2.16)$$

untuk  $n$  besar

$$\frac{1}{n-1} \sum_{t=2}^n Z_t \approx \frac{1}{n-1} \sum_{t=2}^n Z_{t-1} \approx \bar{Z}. \quad (2.17)$$

kemudian dari persamaan (2.16) disederhanakan menjadi

$$\hat{\mu} \approx \frac{1}{1-\phi} (\bar{Z} - \phi \bar{Z}) = \bar{Z}. \quad (2.18)$$

dengan cara yang sama operasi turunan terhadap  $\phi$  sebagai berikut.

$$\frac{\partial S(\phi, \mu)}{\partial \phi} = \sum_{t=2}^n -2[(Z_t - \hat{\mu}) - \hat{\phi}(Z_{t-1} - \hat{\mu})](Z_{t-1} - \hat{\mu}) = 0. \quad (2.19)$$

Sehingga didapatkan nilai estimasi  $\phi$  yaitu

$$\hat{\phi} = \frac{\sum_{t=2}^n (Z_t - \bar{Z})(Z_{t-1} - \bar{Z})}{\sum_{t=2}^n (Z_{t-1} - \bar{Z})^2}. \quad (2.20)$$

Setelah mendapatkan estimasi parameter, dilakukan pengujian signifikansi parameter model. Parameter model AR ( $p$ ) dapat diuji dengan hipotesis sebagai berikut :

$H_0 : \phi_i = 0$  ( Parameter tidak signifikan)

$H_1 : \phi_i \neq 0$  (Parameter signifikan) dengan  $i = 1, 2, \dots, p$

Statistik uji yang digunakan adalah

$$t_{hitung} = \frac{\hat{\phi}_i}{se(\hat{\phi}_i)}. \quad (2.21)$$

Tolak  $H_0$ , jika  $|t_{hitung}| > t_{\alpha/2, (n-n_p)}$  atau  $p$ -value kurang dari  $\alpha$ , dengan  $n$  adalah banyak pengamatan pada data *time series* dan  $n_p$  adalah banyaknya parameter.

### 2.2.3 Cek Diagnosa

Cek diagnosa bertujuan untuk memeriksa apakah model yang diestimasi sudah cocok dengan data yang dimodelkan. Pengujian residual meliputi dua tahapan yaitu pengujian residual *white noise* dan residual berdistribusi normal. Berikut penjelasan dari masing-masing pengujian residual.

#### 2.2.3.1 Pengujian Residual *White Noise*

Residual dikatakan *white noise* jika memenuhi dua sifat yaitu bersifat identik yang berarti mempunyai varians yang konstan dan bersifat *independent* yang berarti antar residual tidak saling berkorelasi atau residual bersifat homogen serta berdistribusi normal. Berikut hipotesis pengujian *white noise* menggunakan Ljung-Box. (Wei, 2006: 153)

$H_0 : \rho_1 = \rho_2 = \dots = \rho_K = 0$  (residual *white noise*)

$H_1 : \text{minimal ada satu } \rho_K \neq 0 \text{ dengan } k = 1, 2, \dots, K \text{ (residual tidak white noise).}$

Statistik uji yang digunakan adalah

$$Q = n(n+2) \sum_{k=1}^K \frac{\hat{\rho}_k^2}{n-k}, \quad (2.22)$$

dengan

$Q$  : statistik uji Ljung-Box  
 $n$  : jumlah data pengamatan  
 $\hat{\rho}_k$  : ACF residual lag ke- $k$ .

Tolak  $H_0$ , jika  $Q > \chi^2_{(\alpha; K-p-q)}$  atau  $p$ -value kurang dari  $\alpha$ , dimana  $p$  dan  $q$  adalah orde AR dan MA.

Pengujian *white noise* terhadap residual yang identik menggunakan pengujian *Lagrange Multiplier* (LM). Pengujian tersebut digunakan untuk mendeteksi efek *Autoregressive Conditional Heteroscedacity* (ARCH). Menurut Enders (2015) mengatakan bahwa pengujian tersebut bertujuan untuk menunjukkan varians residual bukan hanya fungsi dari variabel independen, tapi tergantung pada residual kuadrat periode sebelumnya. Pertama, mendapatkan residual  $\hat{\varepsilon}_t = \hat{n}_t$ , kemudian membentuk deret  $\hat{n}_t^2$  setelah itu dapatkan plot ACF dan PACF untuk melihat apakah deret tersebut mengikuti model AR( $s$ ) seperti persamaan berikut :

$$\hat{n}_t^2 = \theta_0 + \theta_1 \hat{n}_{t-1}^2 + \theta_2 \hat{n}_{t-2}^2 + \dots + \theta_s \hat{n}_{t-s}^2 + a_t. \quad (2.23)$$

Untuk  $t = s+1, s+2, \dots, n$ . Berikut hipotesis dari pengujian *Lagrange Multiplier* :

$H_0$  :  $\theta_1 = \theta_2 = \dots = \theta_s = 0$  (Tidak ada efek ARCH)

$H_1$  : minimal ada satu  $\theta_j \neq 0$ , untuk  $j = 1, 2, \dots, s$  (Terdapat efek

ARCH)

Statistik uji yang digunakan adalah

$$LM = (n-s)R^2, \quad (2.24)$$

dengan,

$$R^2 = \frac{SSR}{SST}$$

*Sum Square of Regression* (SSR) dan *Sum Square Total* (SST) diperoleh dari regresi antara  $\hat{n}_t^2$  dengan  $\hat{n}_{t-1}^2, \hat{n}_{t-2}^2, \dots, \hat{n}_{t-s}^2$  serta  $n$

adalah banyaknya observasi. Tolak  $H_0$ , jika  $LM > \chi^2_{(s)}$  atau  $p$ -value kurang dari  $\alpha$ .

### 2.2.3.2 Pengujian Residual Berdistribusi normal

Pengujian residual berdistribusi normal menggunakan uji *Kolmogorov-Smirnov*. Hipotesis menggunakan uji *Kolmogorov-Smirnov* sebagai berikut :

$H_0 : F_n(a_t) = F_0(a_t)$  (residual berdistribusi normal)

$H_1 : F_n(a_t) \neq F_0(a_t)$  (residual tidak berdistribusi normal)

Statistik uji yang digunakan adalah

$$D = \sup_{a_t} |F_n(a_t) - F_0(a_t)|. \quad (2.25)$$

dengan

$F_n(a_t)$  : fungsi peluang kumulatif dari data sampel

$F_0(a_t)$  : fungsi peluang kumulatif dari distribusi normal

$\sup$  : nilai maksimum dari harga mutlak

$D$  : jarak vertikal terjauh antara  $F_n(a_t)$  dan  $F_0(a_t)$

Tolak  $H_0$ , jika  $D > D_{(1-\alpha);n}$  atau  $p$ -value kurang dari  $\alpha$  dengan

$D_{(1-\alpha);n}$  adalah nilai tabel *Kolmogorov-Smirnov* pada kuantil  $(1-\alpha)$

dan  $n$  merupakan ukuran sampel.

### 2.2.4 Peramalan (*Forecasting*)

Tahapan selanjutnya adalah peramalan untuk menghitung nilai ramalan  $l$  tahap ke depan. Peramalan terdapat dua jenis yaitu peramalan titik dan peramalan interval. Menurut Wei (2006: 88-90) ramalan titik  $l$  tahap ke depan adalah sebagai berikut :

$$\hat{Z}_n(l) = E(Z_{n+l} | Z_n, Z_{n-1}, \dots, Z_1) \quad (2.26)$$

Untuk peramalan interval  $l$  tahap ke depan sebagai berikut :

$$\hat{Z}_n(l) \pm Z_{\alpha/2} \sqrt{\text{var}(e_n(l))} \quad (2.27)$$

dengan  $n$  adalah jumlah data serta  $e_n(l)$  adalah kesalahan ramalan pada  $l$  tahap ke depan.

### 2.2.5 Pemilihan Model Terbaik

Pemilihan model terbaik yang digunakan berdasarkan akurasi ramalan berdasarkan *out-sample*. Pemilihan model terbaik berdasarkan *Root Mean Square Error* (RMSE). Menurut Hyndman dan Koehler (2006) untuk menerapkan dan membandingkan pada metode yang berbeda dengan data yang skalanya sama dapat menggunakan MSE. Namun seringkali RMSE lebih disukai dari pada MSE, karena RMSE dapat disamakan dengan skala dari data yang digunakan. Rumus RMSE sebagai berikut.

$$RMSE = \sqrt{\frac{1}{L} \sum_{l=1}^L (Z_{n+l} - \hat{Z}_n(l))^2} \quad (2.28)$$

dengan

$Z_{n+l}$  : data *out-sample*

$\hat{Z}_n(l)$  : nilai ramalan

$L$  : jumlah data *out-sample*

### 2.3 Model ARIMAX (dengan Efek Variasi Kalender)

Model ARIMAX merupakan model ARIMA yang diberi tambahan variabel prediktor atau variabel *dummy* seperti variasi kalender atau tren deterministik. Model variasi kalender merupakan model *time series* yang digunakan untuk meramalkan data berdasarkan pola musiman dengan periode bervariasi (Karomah & Suhartono, 2014). Berikut model ARIMAX yang mengandung pola tren, musiman, variasi kalender, dan *noise* :

$$Z_t = T_t + S_t + CV_t + N_t, \quad (2.29)$$

atau

$$Z_t = \delta t + \beta_1 M_{1,t} + \dots + \beta_{12} M_{12,t} + \sum_{j=1}^4 \alpha_j D_{j,t-1} + \sum_{j=1}^4 \gamma_j D_{j,t} + \sum_{j=1}^4 \omega_j D_{j,t+1} + \frac{\theta_q(B)}{\phi_p(B)} a_t. \quad (2.30)$$

dengan

$T_t$  : tren

$S_t$  : musiman (bisa dummy atau model sinus)

$CV_t$  : variasi kalender

$N_t$  : *noise* (linier atau non-linier stasioner)

$t$  : *dummy* waktu untuk bulan

$M_{i,t}$  : variabel *dummy* bulan ke- $i$ , dimana  $i = 1, 2, \dots, 12$

$D_{j,t-1}$  : variabel *dummy* satu bulan sebelum hari raya Idul Fitri yang terjadi pada minggu ke- $j$

$D_{j,t}$  : variabel *dummy* saat bulan hari raya Idul Fitri yang terjadi pada minggu ke- $j$

$D_{j,t+1}$  : variabel *dummy* satu bulan sesudah hari raya Idul Fitri yang terjadi pada minggu ke- $j$

dengan  $j = 1, 2, 3, 4$

Ketentuan minggu sebagai berikut :

Minggu I : tanggal 1-7

Minggu II : tanggal 8-15

Minggu III : tanggal 16-23

Minggu IV : tanggal 24- terakhir.

## 2.4 Uji Linieritas

Uji linieritas yang dikenalkan oleh Terasvirta, Lin, dan Granger (1993) dapat dilakukan melalui statistik uji F. Uji Terasvirta termasuk dalam kelompok uji tipe *Lagrange Multiplier*. Hipotesis dalam melakukan uji Terasvirta dengan statistik uji F sebagai berikut.

$H_0$  :  $f(x)$  adalah fungsi linier dalam  $x$  atau model linier

$H_1$  :  $f(x)$  adalah fungsi non-linier dalam  $x$  atau model non-linier

Prosedur untuk memperoleh statistik uji F sebagai berikut.

- i. Regresikan  $Z_t$  pada  $Z_{t-1}, \dots, Z_{t-p}$  kemudian hitung residual  $\hat{u}_t$  serta hitung jumlah kuadrat residual yaitu  $SSR_0 = \sum \hat{u}_t^2$

- ii. Regresikan  $\hat{u}_t$  pada  $Z_{t-1}, \dots, Z_{t-p}$  dan  $m$  prediktor tambahan, kemudian hitung residual  $\hat{v}_t$  dimana  $\hat{v}_t = \hat{u}_t - \text{fits}(\hat{u})$  dan hitung jumlah kuadrat residual yaitu  $SSR_1 = \sum \hat{v}_1^2$
- iii. Menghitung nilai statistik uji F

$$F_{hitung} = \frac{(SSR_0 - SSR_1) / m}{SSR_1 / (n - 1 - p - m)}$$

dimana

$n$  : banyak pengamatan

$m$  : banyaknya prediktor tambahan

$p$  : jumlah prediktor pada regresi awal

Tolak  $H_0$ , jika  $F_{hitung} > F_{tabel}$  atau  $p\text{-value}$  kurang dari  $\alpha$ , dengan derajat bebas  $m$  dan  $(n-p-1-m)$  yang berarti model non-linier.

## 2.5 Neural Network

*Neural Network* (NN) merupakan sistem pemrosesan informasi yang memiliki karakteristik sama dengan jaringan saraf manusia dan metode ini sering digunakan untuk pemodelan non-linier. Jaringan saraf tiruan diperkenalkan oleh McCulloch & Pitts di tahun 1943. McCulloch dan Pitts menyimpulkan bahwa kombinasi dari beberapa *neuron* sederhana menjadi sebuah sistem *neural* akan meningkat kemampuan komputasinya. Setiap *neuron* dihubungkan dengan *neuron* lainnya dengan suatu *connecting link*, yang disebut dengan *weight* atau bobot. Setiap neuron menggunakan fungsi aktivasi untuk menentukan output. Lapisan-lapisan penyusun jaringan saraf tiruan dapat dibagi menjadi tiga yaitu :(Siang, 2009: 9)

### 1. Lapisan Input

*Node* di dalam lapisan input disebut unit-unit input. Unit-unit input tersebut menerima pola inputan dari luar yang menggambarkan dari suatu masalah. Banyak *node* atau neuron pada lapisan unit tergantung pada banyaknya input dalam model.

### 2. Lapisan Tersembunyi (*hidden layer*)


*Node* di dalam lapisan tersembunyi disebut unit-unit tersembunyi. Dimana outputnya dari lapisan ini tidak secara

langsung diamati. Lapis tersembunyi terletak diantara lapis unit dan lapis output.

### 3. Lapisan Output

*Node* pada lapisan output dinamakan sebagai unit-unit output. Output dari permasalahan ini merupakan output solusi NN terhadap suatu permasalahan.

Penelitian ini menggunakan arsitektur *neural network* jaringan *Multi Layer Perceptron* (MLP). Jaringan *Multi Layer Perceptron* adalah jaringan yang memiliki satu atau lebih pada lapisan tersembunyi (*hidden layer*). Jaringan multilapis ini perluasan dari layar tunggal, dimana unit-unit input dihubungkan ke unit *hidden* kemudian di proses dengan fungsi aktivasi setelah itu di salurkan ke unit output. Arsitektur FFNN sering dikenal dengan Multi Layer Perceptron (MLP). Berikut arsitektur FFNN pada Gambar 2.1



**Gambar 2.1** Arsitektur Jaringan Multilapis



Model umum persamaan FFNN dengan satu *hidden layer* dapat ditulis sebagai berikut :

$$\hat{Z}_t = b^o + \sum_{j=1}^q \left\{ \omega_j^o \cdot f_j^h(.) \left( b_j^h + \sum_{i=1}^p w_{ji}^h Z_{t-i} \right) \right\},$$

dengan :

$\hat{Z}_t$  = variabel *output*,

$b^o$  = bias neuron pada lapisan *output*,

$\omega_j^o$  = pembobot neuron ke-  $j$  pada lapisan tersembunyi yang menuju neuron pada lapisan *output*,

$f_j^h(.)$  = fungsi aktivasi neuron ke-  $j$  pada lapisan tersembunyi,


$b_j^h$  = bias neuron ke-  $j$  pada lapisan tersembunyi,

$\omega_{ji}^h$  = pembobot *input* ke-  $i$  yang menuju ke neuron pada lapisan tersembunyi,

$Z_{t-i}$  = variabel *input*.

Pada penelitian ini, fungsi aktivasi yang digunakan adalah sigmoid biner untuk *hidden layer* serta fungsi aktifasi linier untuk *output layer*. Fungsi sigmoid terletak pada interval 0 sampai 1. Fungsi sigmoid biner dapat dirumuskan sebagai berikut :


$$f(x) = \frac{1}{1 + e^{-x}}. \quad (2.31)$$



**Gambar 2.2** Fungsi Sigmoid Biner

kemudian fungsi linier atau fungsi identitas dirumuskan sebagai berikut :

$$f(x) = x. \quad (2.32)$$



**Gambar 2.3** Fungsi Linier

## 2.6 Model ARCH dan GARCH

Pada umumnya, pemodelan data deret waktu dilakukan dengan asumsi varians residual konstan atau homoskedastisitas yaitu sebesar  $\sigma_t^2$ . Pada kenyataannya, banyak data *time series* yang mempunyai varians residual yang bersifat heteroskedastisitas, khususnya pada bidang keuangan. Hal ini menyebabkan pemodelan dengan menggunakan analisis *time series* biasa yang mempunyai asumsi heteroskedastisitas tidak dapat digunakan.

Model ARCH memperbolehkan adanya asumsi varians yang bersifat heteroskedastisitas yang pertama kali dikenalkan oleh Engle (1982). Model tersebut mengasumsikan bahwa kondisional varians hari ini dipengaruhi oleh waktu sebelumnya. Misalkan diberikan model regresi standar dengan residual yang tidak berkorelasi.

$$Y_t = \theta_0 + \theta_1 x_t + \varepsilon_t \quad (2.33)$$

dengan  $\varepsilon_t = n_t$  dan  $n_t$  memiliki varians berubah setiap waktu. Menurut Engle (1982) model residual diasumsikan sebagai berikut

$$n_t = \sigma_t e_t \quad (2.34)$$

dengan  $e_t$  merupakan variabel random yang identik dan independen dengan mean nol dan varians satu, serta independen terhadap  $n_{t-i}$ ,

$$\sigma_t^2 = \theta_0 + \theta_1 \hat{n}_{t-1}^2 + \theta_2 \hat{n}_{t-2}^2 + \dots + \theta_s \hat{n}_{t-s}^2 \quad (2.35)$$

Persamaan diatas merupakan peramalan optimal dari  $n_t^2$ , jika  $n_t^2$  tersebut mengikuti model AR ( $s$ )

$$\hat{n}_t^2 = \theta_0 + \theta_1 \hat{n}_{t-1}^2 + \theta_2 \hat{n}_{t-2}^2 + \dots + \theta_s \hat{n}_{t-s}^2 + a_t \quad (2.36)$$

dengan  $a_t \sim N(0, \sigma^2)$  merupakan *white noise*. Menurut Engle (1982) bahwa model dari residual  $n_t$  dengan varians yang ditunjukkan pada persamaan (2.34) dan (2.35) atau pada persamaan (2.36) sebagai model *Autoregressive Conditional Heteroscedacity* (ARCH). Untuk lebih spesifiknya, model ARCH dengan orde  $s$  ditulis ARCH ( $s$ ).

Pada tahun 1986, peneliti bernama Bollerslev mengembangkan model ARCH menjadi model *Generalized Autoregressive Conditional Heteroscedacity* (GARCH). Persamaan varians residual GARCH ( $r, s$ ) sebagai berikut :

$$\sigma_t^2 = \theta_0 + \phi_1 \sigma_{t-1}^2 + \dots + \phi_r \sigma_{t-r}^2 + \dots + \theta_1 \hat{n}_{t-1}^2 + \dots + \theta_s \hat{n}_{t-s}^2 \quad (2.37)$$

dengan  $r$  merupakan orde pada AR,  $s$  merupakan orde pada MA,  $\sigma_t^2 > 0$ , diasumsikan  $\sigma_t^2 > 0$ ,  $\phi_r \geq 0$  dan  $\theta_s \geq 0$ . Pada model GARCH varians residual ( $\sigma_t^2$ ) tidak hanya dipengaruhi oleh kuadrat residual periode yang lalu ( $\hat{n}_{t-s}^2$ ) melainkan varians residual periode lalu ( $\sigma_{t-r}^2$ ) juga berpengaruh.

## 2.7 Model Hybrid

*Hybrid* merupakan gabungan dari beberapa model peramalan. Pada penelitian ini menggunakan model peramalan ARIMAX sebagai pemodelan linier sedangkan *Neural Network* sebagai pemodelan non linier. Menurut Zhang (2003) memperkenalkan model *hybrid* hasil kombinasi model linier ARIMA dengan level satu dan model non-linier *Neural Network* pada level dua. Model *hybrid* digunakan karena di dalam dunia nyata jarang ditemukan pada deret waktu yang murni linier saja ataupun murni non-linier, sehingga dengan adanya kombinasi dari model linier dan non-linier akan menangkap secara simultan pola linier dan non-linier pada deret waktu tersebut. Berikut model umum dari model *hybrid*

$$Z_t = L_t + N_t + e_t \quad (2.38)$$

dengan

$L_t$  : komponen linier

$N_t$  : komponen non-linier

Model ARIMAX dalam model *hybrid* bertujuan untuk menyelesaikan kasus model linier, dimana residual dari model tersebut terdapat informasi hubungan non-linier. Berikut persamaan residual dari model tersebut

$$a_t = Z_t - \hat{L}_t, \quad (2.39)$$

dengan

$\hat{L}_t$  : nilai ramalan pada waktu ke-t

$Z_t$  : data awal pada waktu ke-t

Langkah selanjutnya adalah memodelkan residual dari model ARIMAX menggunakan *Neural Network*. Hasil ramalan dari *Neural Network* dilambangkan dengan  $\hat{N}_t$ . Secara keseluruhan hasil peramalan dinyatakan dalam persamaan sebagai berikut

$$\hat{Z}_t = \hat{L}_t + \hat{N}_t, \quad (2.40)$$

$\hat{Z}_t$  merupakan gabungan nilai peramalan dari model ARIMAX serta nilai ramalan *Neural Network*.

## **2.8 Inflow dan Outflow Uang Kartal**

Transaksi penarikan uang rupiah (*outflow*) merupakan informasi mengenai aliran uang kertas dan uang logam yang keluar dari Bank Indonesia kepada perbankan dan masyarakat, terdiri dari penarikan bank umum, penarikan non-bank, dan kas keliling dalam rangka penukaran. Transaksi penyetoran uang rupiah (*inflow*) merupakan informasi mengenai aliran uang kertas dan uang logam yang masuk dari perbankan dan masyarakat ke Bank Indonesia, terdiri dari setoran bank umum, setoran non-bank, dan kas keliling dalam rangka hasil penukaran. Selisih transaksi penarikan/penyetoran uang rupiah merupakan selisih antara transaksi penyetoran uang rupiah (*inflow*) dan transaksi penarikan uang rupiah (*outflow*). *Net inflow* transaksi uang kartal berarti jumlah penyetoran uang kartal ke Bank Indonesia lebih besar daripada jumlah penarikan uang kartal dari Bank Indonesia. Sementara itu, *net outflow* transaksi uang kartal berarti jumlah penyetoran uang rupiah (*inflow*) lebih kecil daripada penarikan uang rupiah (*outflow*). (Bank Indonesia, 2016)

*Halaman ini sengaja dikosongkan*

## BAB III METODOLOGI PENELITIAN

### 3.1 Sumber Data

Data yang digunakan dalam penelitian ini adalah data sekunder yang diperoleh dari Bank Indonesia. Data yang diambil merupakan data *inflow* dan *outflow* uang kartal setiap bulannya pada tahun 2004 hingga 2016 di Provinsi Jawa Barat. Data akan dibagi menjadi dua bagian yaitu *in-sample* dan *out-sample*. Data *in-sample* dimulai pada bulan Januari 2004 hingga Desember 2015, sedangkan data *out-sample* dimulai periode bulan Januari 2016 hingga Desember 2016.

### 3.2 Variabel Penelitian

Spesifikasi variabel yang digunakan dalam penelitian ini adalah sebagai berikut :

$Z_{1,t}$  : *Outflow* uang kartal di Bank Indonesia Jawa Barat pada bulan ke- $t$ .

$Z_{2,t}$  : *inflow* uang kartal di Bank Indonesia Jawa Barat pada bulan ke- $t$ .

$t$  : tren kenaikan *inflow* atau *outflow* ( $t = 1, 2, \dots, n$ )

Penelitian ini menggunakan variabel dummy bulan dan variabel dummy Idul Fitri. Berikut penjelasan dari variabel dummy bulan :

$$M_{1,t} = \begin{cases} 1, & \text{bulan Januari} \\ 0, & \text{bulan lainnya} \end{cases}$$

:

$$M_{12,t} = \begin{cases} 1, & \text{bulan Desember} \\ 0, & \text{bulan lainnya} \end{cases}$$

Berikut penjelasan dari variabel *dummy* Idul Fitri yang terjadi pada minggu ke- $j$  ( $j = 1, 2, 3, 4$ ) :

a) Efek satu bulan sebelum Idul Fitri

$$D_{1,t-1} = \begin{cases} 1, & \text{bulan ke } (t-1) \text{ hari raya Idul Fitri minggu ke-1} \\ 0, & \text{bulan lainnya} \end{cases}$$

$$D_{2,t-1} = \begin{cases} 1, & \text{bulan ke } (t-1) \text{ hari raya Idul Fitri minggu ke-2} \\ 0, & \text{bulan lainnya} \end{cases}$$

$$D_{3,t-1} = \begin{cases} 1, & \text{bulan ke } (t-1) \text{ hari raya Idul Fitri minggu ke-3} \\ 0, & \text{bulan lainnya} \end{cases}$$

$$D_{4,t-1} = \begin{cases} 1, & \text{bulan ke } (t-1) \text{ hari raya Idul Fitri minggu ke-4} \\ 0, & \text{bulan lainnya} \end{cases}$$

b) Efek saat bulan Idul Fitri

$$D_{1,t} = \begin{cases} 1, & \text{bulan ke } (t) \text{ hari raya Idul Fitri minggu ke-1} \\ 0, & \text{bulan lainnya} \end{cases}$$

$$D_{2,t} = \begin{cases} 1, & \text{bulan ke } (t) \text{ hari raya Idul Fitri minggu ke-2} \\ 0, & \text{bulan lainnya} \end{cases}$$

$$D_{3,t} = \begin{cases} 1, & \text{bulan ke } (t) \text{ hari raya Idul Fitri minggu ke-3} \\ 0, & \text{bulan lainnya} \end{cases}$$

$$D_{4,t} = \begin{cases} 1, & \text{bulan ke } (t) \text{ hari raya Idul Fitri minggu ke-4} \\ 0, & \text{bulan lainnya} \end{cases}$$

c) Efek satu bulan setelah Idul Fitri

$$D_{1,t+1} = \begin{cases} 1, & \text{bulan ke } (t+1) \text{ hari raya Idul Fitri minggu ke-1} \\ 0, & \text{bulan lainnya} \end{cases}$$

$$D_{2,t+1} = \begin{cases} 1, & \text{bulan ke } (t+1) \text{ hari raya Idul Fitri minggu ke-2} \\ 0, & \text{bulan lainnya} \end{cases}$$

$$D_{3,t+1} = \begin{cases} 1, & \text{bulan ke } (t+1) \text{ hari raya Idul Fitri minggu ke-3} \\ 0, & \text{bulan lainnya} \end{cases}$$

$$D_{4,t+1} = \begin{cases} 1, & \text{bulan ke } (t+1) \text{ hari raya Idul Fitri minggu ke-4} \\ 0, & \text{bulan lainnya} \end{cases}$$

Ketentuan minggu sebagai berikut :

Minggu I : tanggal 1-7

Minggu II : tanggal 8-15

Minggu III : tanggal 16-23

Minggu IV : tanggal 24- terakhir

Tanggal terjadinya hari raya Idul Fitri Tahun 2004-2015 disajikan pada Tabel 3.1



**Tabel 3.1** Tanggal Terjadinya Hari Raya Idul Fitri

Tahun	Tanggal Idul Fitri	Minggu Idul Fitri
2004	15-16 November	Minggu ke-3
2005	03-04 November	Minggu ke-1
2006	23-24 Oktober	Minggu ke-4
2007	12-13 Oktober	Minggu ke-2
2008	01-02 Oktober	Minggu ke-1
2009	21-22 September	Minggu ke-3
2010	10-11 September	Minggu ke-2
2011	30-31 Agustus	Minggu ke-4
2012	19-20 Agustus	Minggu ke-3
2013	08-09 Agustus	Minggu ke-2
2014	28-29 Juli	Minggu ke-4
2015	17-18 Juli	Minggu ke-3

### 3.3 Langkah Penelitian

Langkah analisis yang digunakan dalam penelitian ini adalah sebagai berikut :

1. Untuk mengetahui karakteristik data *inflow* dan *outflow* di Jawa Barat maka,
  - a. Melakukan analisis deskriptif pada data *inflow* dan *outflow* di Jawa Barat dengan menghitung nilai rata-rata, varians, maksimum, dan minimum.
  - b. Membuat grafik *time series plot* data *inflow* dan *outflow* di Jawa Barat untuk mengidentifikasi adanya tren, musiman, dan variasi kalender.
2. Untuk pemodelan dan peramalan data *inflow* dan *outflow* di Jawa Barat menggunakan metode ARIMAX dilakukan langkah-langkah sebagai berikut :
  - a. Data dibagi menjadi dua, yaitu data *in-sample* dan *out-sample*.

- b. Identifikasi pada *plot time series*, asumsikan data mengandung pola tren, musiman, variasi kalender, dan *error* yang belum acak.
- c. Menentukan variabel *dummy* berdasarkan tren, musiman, dan variasi kalender yang sudah dijelaskan diatas.
- d. Memodelkan pola data tren, musiman, dan variasi kalender secara simultan :

$$Z_t = \delta t + \beta_1 M_{1,t} + \dots + \beta_{12} M_{12,t} + \sum_{j=1}^4 \alpha_j D_{j,t-1} +$$

$$\sum_{j=1}^4 \gamma_j D_{j,t} + \sum_{j=1}^4 \omega_j D_{j,t+1} + a_t$$

- e. Cek apakah residual ( $a_t$ ) sudah memenuhi asumsi *white noise*. Jika residual sudah *white noise* maka berhenti dan dilakukan peramalan. Jika residual belum *white noise* maka  $a_t$  mengandung auto korelasi dan lanjut ke tahap (f).
- f. Memodelkan  $a_t$  dengan ARIMA melalui prosedur Box-Jenkins. Didapatkan orde  $p$  dan orde  $q$ .
- g. Melakukan pemodelan ARIMAX

$$Z_t = \delta t + \beta_1 M_{1,t} + \dots + \beta_{12} M_{12,t} + \sum_{j=1}^4 \alpha_j D_{j,t-1} +$$

$$\sum_{j=1}^4 \gamma_j D_{j,t} + \sum_{j=1}^4 \omega_j D_{j,t+1} + \frac{\theta_q(B)}{\phi_p(B)} a_t$$

- h. Melakukan pemeriksaan diagnostik residual ( $a_t$ ) meliputi uji asumsi *white noise* dan uji normalitas.
- i. Melakukan pemeriksaan  $a_t^2$  mengandung ARCH atau GARCH dengan pengujian *Lagrange Multiplier*. Jika  $a_t^2$  tidak mengandung efek ARCH atau GARCH maka model yang digunakan hanya ARIMAX kemudian dilakukan peramalan, namun jika ada efek ARCH atau GARCH

dilakukan pemodelan dengan ARIMAX-GARCH dan dilanjutkan ke tahap (j).

- Model dari ARIMAX sebagai berikut :

$$Z_t = \delta t + \beta_1 M_{1,t} + \dots + \beta_{12} M_{12,t} + \sum_{j=1}^4 \alpha_j D_{j,t-1} + \sum_{j=1}^4 \gamma_j D_{j,t} + \sum_{j=1}^4 \omega_j D_{j,t+1} + \frac{\theta_q(B)}{\phi_p(B)} a_t$$

- Model dari GARCH ( $r, s$ ) sebagai berikut :

$$\sigma_t^2 = \theta_0 + \phi_1 \sigma_{t-1}^2 + \dots + \phi_r \sigma_{t-r}^2 + \dots + \theta_1 \hat{n}_{t-1}^2 + \dots + \theta_s \hat{n}_{t-s}^2$$

- j. Melakukan peramalan pada data *inflow* dan *outflow* di Jawa Barat menggunakan ARIMAX-GARCH.
3. Untuk pemodelan dan peramalan *inflow* dan *outflow* di Jawa Barat menggunakan metode *Neural Network* dilakukan langkah-langkah sebagai berikut
  - a. Melakukan *preprocessing* data

Pada bagian *preprocessing*, memastikan bahwa rentang data untuk input NN telah sama. Rentang nilai yang digunakan sesuai dengan fungsi aktivasi. Contoh jika menggunakan *sigmoid biner* maka rentang nilai yang digunakan adalah 0 sampai 1. Sehingga input data akan ditransformasi ke angka antara nilai 0 sampai 1. Rumus yang digunakan adalah

$$y = \left[ \frac{x - \min(x)}{\max(x) - \min(x)} \right] \quad 3.1$$

- b. Menentukan input yang digunakan

Input yang digunakan berdasarkan lag yang signifikan pada plot PACF.

- c. Menentukan arsitektur FFNN

Pada penelitian ini digunakan lapis input, satu lapis tersembunyi kemudian dicoba 1-5, 10, dan 15 *hidden neuron*, serta lapis *output*. Fungsi aktivasi yang digunakan adalah *sigmoid biner* pada lapis tersembunyi, dan fungsi identitas pada lapis output.

- d. Melakukan proses training dengan *backpropagation*, dimana mengestimasi nilai bobot yang akan menghasilkan *output* sedekat mungkin dengan input.
- e. Meramalkan data
- f. Melakukan *postprocessing* data


Setelah didapatkan peramalan, langkah selanjutnya adalah melakukan transformasi kembali ke nilai semula dengan rumus sebagai berikut,

$$x = [y(\max(x) - \min(x))] + \min(x) \quad 3.2$$


- 4. Untuk pemodelan dan peramalan *inflow* dan *outflow* di Jawa Barat menggunakan metode ARIMAX-NN dan GARCH dilakukan langkah-langkah sebagai berikut
  - a. Peramalan dengan menggunakan model linier yaitu ARIMAX.
  - b. Kemudian didapatkan nilai residual, residual dimodelkan dengan menggunakan model non linier yaitu FFNN dengan metode *backpropagation*.
  - c. Mendapatkan ramalan hibrida dengan menjumlahkan hasil ramalan model (ARIMAX) dan hasil ramalan residual model non-linier (*Neural Network*).
  - d. Apabila residual tidak bersifat homogen maka dilakukan deteksi ARCH atau GARCH.

### 3.4 Diagram Alir Penelitian


Diagram alir pada penelitian ini adalah memodelkan ARIMAX, *Neural Network* dan *Hybrid* ARIMAX-NN. Untuk lebih jelasnya, berikut penjelasan dari diagram alir




**Gambar 3.1** Diagram Alir Penelitian



**Gambar 3.2** Diagram Alir Model ARIMAX



**Gambar 3.3** Diagram Alir Model NN



**Gambar 3.4** Diagram Alir Model *Hybrid* ARIMAX-NN



## BAB IV ANALISIS DAN PEMBAHASAN

Berlandaskan pada tujuan penelitian yaitu mendapatkan model yang tepat pada data *inflow* dan *outflow* di Kantor Perwakilan Bank Indonesia Provinsi Jawa Barat menggunakan metode ARIMAX, *Neural Network*, *Hybrid* ARIMAX-NN dan GARCH pada periode pengamatan. Pembahasan diawali dengan melakukan eksplorasi data untuk mengetahui karakteristik dari data *inflow* dan *outflow*, kemudian dilakukan pemodelan menggunakan ARIMAX, *Neural Network*, *Hybrid* ARIMAX-NN dan GARCH. Metode terbaik didapatkan dengan membandingkan nilai RMSE *out-sample* terkecil, kemudian dilakukan peramalan *inflow* dan *outflow* uang kartal di Kantor Perwakilan Bank Indonesia Provinsi Jawa Barat untuk masa yang akan datang. Namun pada penelitian ini akan dimulai dengan menganalisis data studi simulasi yang mengandung pola tren, musiman, dan variasi kalender.

### 4.1 Studi Simulasi

Studi simulasi bertujuan untuk mengetahui pola data yang dimodelkan. Pola tersebut terdiri dari pola tren, musiman, variasi kalender, dan *noise*. Kemudian akan dilakukan 4 skenario. Setiap skenario memiliki komponen tetap dan komponen berbeda. Komponen tetap yaitu tren dan variasi kalender sedangkan komponen berbeda yaitu musiman dan *noise*. Komponen berbeda pada musiman bersifat homogen dan heterogen serta *noise* bersifat linier mengikuti proses AR(1) dan non-linier mengikuti proses ESTAR-2. Persamaan model studi simulasi sebagai berikut.

$$Z_t = T_t + S_t + CV_t + N_t,$$

dengan

$T_t$  : tren

$S_t$  : musiman (homogen atau heterogen)

$CV_t$  : variasi kalender

$N_t$  : *noise* (linier atau non-linier stasioner)

Untuk lebih jelasnya, persamaan setiap komponen untuk skenario 1 hingga skenario 4 akan dijelaskan pada subab 4.1.1 hingga 4.1.4. Tanggal kejadian hari raya Idul Fitri tahun 2001 hingga 2016 dijelaskan pada Tabel 4.1.

**Tabel 4.1** Tanggal Kejadian Idul Fitri Tahun 2001-2016

Tahun	Tanggal Idul Fitri	Minggu Terjadinya Idul Fitri	Variabel Dummy		
			$D_{j,t-1}$	$D_{j,t}$	$D_{j,t+1}$
2001	17-18 Desember	Minggu ke-3	November	Desember	Januari
2002	6-7 Desember	Minggu ke-1	November	Desember	Januari
2003	25-26 November	Minggu ke-4	Oktober	November	Desember
2004	13-14 November	Minggu ke-2	Oktober	November	Desember
2005	03-04 November	Minggu ke-1	Oktober	November	Desember
2006	23-24 Oktober	Minggu ke-4	September	Oktober	November
2007	12-13 Oktober	Minggu ke-2	September	Oktober	November
2008	1-2 Oktober	Minggu ke-1	September	Oktober	November
2009	20-21 September	Minggu ke-3	Agustus	September	Oktober
2010	09-10 September	Minggu ke-2	Agustus	September	Oktober
2011	30-31 Agustus	Minggu ke-4	Juli	Agustus	September
2012	18-19 Agustus	Minggu ke-3	Juli	Agustus	September
2013	08-09 Agustus	Minggu ke-3	Juli	Agustus	September
2014	28-29 Juli	Minggu ke-4	Juni	Juli	Agustus
2015	19-20 Juli	Minggu ke-3	Juni	Juli	Agustus
2016	06-07 juli	Minggu ke-1	Juni	Juli	Agustus

#### 4.1.1 Skenario 1

Pada skenario 1, membangkitkan data bulanan mulai dari Januari 2001 hingga Desember 2016 yang bersifat homogen dan mengikuti model linier AR(1). Diberikan persamaan untuk setiap masing-masing komponen kemudian dilakukan replikasi sebanyak lima kali. Replikasi dibedakan dengan membangkitkan  $a_t$  sebanyak lima kali. Berikut persamaan untuk setiap masing-masing komponen.

$$T_t = 0,3t$$

$$S_t = 8M_{1,t} + 10M_{2,t} + 14M_{3,t} + 23M_{4,t} + 25M_{5,t} + 28M_{6,t} + 30M_{7,t} + 26M_{8,t} + 24M_{9,t} + 22M_{10,t} + 16M_{11,t} + 12M_{12,t}$$

Berdasarkan Gambar 4.1 (a) merupakan plot simulasi untuk replikasi pertama yang mengindikasikan adanya pola tren, musiman, dan variasi kalender hari raya Idul Fitri. Pola tren yaitu kenaikan yang terjadi pada tiap tahun, kemudian pola musiman yaitu terjadinya pola yang berulang pada bulan-bulan tertentu dimana terjadi kenaikan dan penurunan dan terdapat pola yang berulang di setiap tahunnya yang disebabkan oleh adanya efek variasi kalender. Kemudian pada Gambar 4.1 (b), terlihat pada komponen residual pada lag 1 memiliki pola hubungan yang linier. Jika dilihat dari *box plot* pada Gambar 4.1 (c) pada bulan Juli,

Agustus, dan September memiliki varians yang lebih tinggi dibandingkan pada bulan-bulan lainnya hal tersebut dikarenakan efek variasi kalender namun jika dianalisis terpisah pada Gambar 4.1 (d) pada bulan hari raya dan bulan sebelum hari raya Idul Fitri cenderung lebih tinggi jika dibandingkan dengan bulan-bulan biasa. Kemudian jika dilihat dari varians pada setiap bulannya, mengindikasikan bahwa data tersebut homogen. Setelah itu, akan dianalisis menggunakan metode ARIMAX, *Neural Network*, dan *Hybrid ARIMAX-NN*.

### A. ARIMAX Untuk Skenario 1

Tahap awal pembentukan model ARIMAX adalah mengacu pada pemodelan regresi *time series*. Berikut model *regresi time series* untuk data simulasi.

$$\begin{aligned} Z_t = & \delta t + \beta_1 M_{1,t} + \beta_2 M_{2,t} + \beta_3 M_{3,t} + \beta_4 M_{4,t} + \beta_5 M_{5,t} + \beta_6 M_{6,t} + \beta_7 M_{7,t} \\ & + \beta_8 M_{8,t} + \beta_9 M_{9,t} + \beta_{10} M_{10,t} + \beta_{11} M_{11,t} + \beta_{12} M_{12,t} + \gamma_1 D_{1,t} + \gamma_2 D_{2,t} \\ & + \gamma_3 D_{3,t} + \gamma_4 D_{4,t} + \alpha_1 D_{1,t-1} + \alpha_2 D_{2,t-1} + \alpha_3 D_{3,t-1} + \alpha_4 D_{4,t-1} + a_t \end{aligned}$$

Kemudian dilakukan estimasi parameter dari model regresi *time series*. Hasil estimasi parameter tersebut ditampilkan pada Tabel 4.2.

Berdasarkan Tabel 4.2, hasil uji signifikansi parameter model regresi *time series* untuk replikasi ke satu pada skenario 1 diperoleh parameter yang sudah signifikan. Hal tersebut dikarenakan semua *p-value* pada semua parameter kurang dari  $\alpha$  (0,05). Sehingga persamaan regresi *time series* untuk replikasi ke satu pada skenario 1 sebagai berikut.

$$\begin{aligned} Z_t = & 0,28t + 9M_{1,t} + 11,12M_{2,t} + 14,77M_{3,t} + 23,41M_{4,t} + 25,70M_{5,t} \\ & + 28,19M_{6,t} + 30,37M_{7,t} + 26,41M_{8,t} + 25,25M_{9,t} + 23,74M_{10,t} \\ & + 16,96M_{11,t} + 12,85M_{12,t} + 5,57D_{1,t} + 22,75D_{2,t} + 50,91D_{3,t} \\ & + 69,03D_{4,t} + 39,92D_{1,t-1} + 29,56D_{2,t-1} + 25,93D_{3,t-1} + 19,94D_{4,t-1} \\ & + a_t \end{aligned}$$

**Tabel 4.2** Estimasi Parameter Regresi *Time Series* Replikasi Satu

Parameter	Estimasi	Standar Error	<i>t-value</i>	<i>P-value</i>
$\delta$	0,28	0,0026	111,21	<0,0001
$\beta_1$	9,00	0,513	17,56	<0,0001
$\beta_2$	11,12	0,514	21,63	<0,0001
$\beta_3$	14,77	0,515	28,67	<0,0001
$\beta_4$	23,41	0,516	45,32	<0,0001
$\beta_5$	25,70	0,517	49,64	<0,0001
$\beta_6$	28,19	0,524	53,71	<0,0001
$\beta_7$	30,37	0,538	56,40	<0,0001
$\beta_8$	26,41	0,539	48,92	<0,0001
$\beta_9$	25,25	0,546	46,20	<0,0001
$\beta_{10}$	23,74	0,558	42,53	<0,0001
$\beta_{11}$	16,96	0,553	30,65	<0,0001
$\beta_{12}$	12,85	0,536	23,95	<0,0001
$\gamma_1$	5,57	1,081	5,16	<0,0001
$\gamma_2$	22,7 5	0,936	24,29	<0,0001
$\gamma_3$	50,91	0,934	54,50	<0,0001
$\gamma_4$	69,03	0,936	73,70	<0,0001
$\alpha_1$	39,92	1,084	36,82	<0,0001
$\alpha_2$	29,56	0,936	31,56	<0,0001
$\alpha_3$	25,93	0,934	27,77	<0,0001
$\alpha_4$	19,94	0,934	21,35	<0,0001

Persamaan pada model regresi *time series* untuk replikasi satu hingga replikasi lima menghasilkan residual yang belum *white noise*, karena *p-value* yang kurang dari 0,05 pada Tabel 4.3.


**Tabel 4.3** Uji Asumsi *White Noise* Residual Regresi *Time Series* Skenario 1

Hingga Lag ke-	Replikasi 1			Replikasi 2			Replikasi 3		
	Uji <i>White Noise</i>			Uji <i>White Noise</i>			Uji <i>White Noise</i>		
	$\chi^2$	df	<i>P-value</i>	$\chi^2$	df	<i>P-value</i>	$\chi^2$	Df	<i>P-value</i>
6	116,68	6	<0,0001	147,6	6	<0,0001	123,64	6	<0,0001
12	120,91	12	<0,0001	152,34	12	<0,0001	129,4	12	<0,0001
18	132,77	18	<0,0001	157,93	18	<0,0001	132,38	18	<0,0001
24	160,5	24	<0,0001	181,97	24	<0,0001	148,73	24	<0,0001
30	179,32	30	<0,0001	208,1	30	<0,0001	155,6	30	<0,0001
36	197,61	36	<0,0001	215,22	36	<0,0001	175,3	36	<0,0001

**Tabel 4.3** Uji Asumsi *White Noise* Residual Regresi *Time Series* (lanjutan)

Hingga Lag ke-	Replikasi 4			Replikasi 5		
	Uji <i>White Noise</i>			Uji <i>White Noise</i>		
	$\chi^2$	Df	P-value	$\chi^2$	Df	P-value
6	251,73	6	<0,0001	153,64	6	<0,0001
12	304,64	12	<0,0001	157,07	12	<0,0001
18	319,78	18	<0,0001	168,34	18	<0,0001
24	323,12	24	<0,0001	179,36	24	<0,0001
30	332,71	30	<0,0001	182,57	30	<0,0001
36	385,71	36	<0,0001	211,64	36	<0,0001

Kemudian tahap pertama yang dilakukan ketika residual belum *white noise* adalah pembentukan model ARIMA berdasarkan plot ACF dan PACF residual regresi *time series* guna mendapatkan model yang memenuhi asumsi independen yang ditampilkan pada Gambar 4.2.



**Gambar 4.2** Plot ACF dan PACF Residal Regresi *Time Series* Replikasi Satu

Berdasarkan Gambar 4.2, plot PACF *cut off* setelah lag 1 serta ACF membentuk pola *dies down* sehingga model ARIMA yang dapat dibentuk adalah model ARIMA (1,0,0). Hasil estimasi parameter untuk model ARIMA (1,0,0) ditampilkan pada tabel 4.4 yang menunjukkan semua parameter signifikan serta menghasilkan residual yang independen ditampilkan pada Tabel 4.5.

**Tabel 4.4** Estimasi Parameter dan Uji signifikansi Parameter ARIMA Skenario 1

Replikasi	Model	Parameter	Estimasi	t-value	P-value	Keterangan
1	ARIMA(1,0,0)	$\phi_1$	0,60768	10,21	<,0001	Signifikan
2	ARIMA(1,0,0)	$\phi_1$	0,70701	12,95	<,0001	Signifikan
3	ARIMA(1,0,0)	$\phi_1$	0,65490	11,58	<,0001	Signifikan
4	ARIMA(1,0,0)	$\phi_1$	0,73957	14,69	<,0001	Signifikan
5	ARIMA(1,0,0)	$\phi_1$	0,66654	11,92	<,0001	Signifikan

**Tabel 4.5 Uji Asumsi Independen Skenario 1**

Hingga Lag ke-	Replikasi 1			Replikasi 2			Replikasi 3		
	Uji White Noise			Uji White Noise			Uji White Noise		
	$\chi^2$	df	P-value	$\chi^2$	df	P-value	$\chi^2$	Df	P-value
6	7,31	5	0,1988	5,47	5	0,3617	2,7	5	0,7458
12	16,96	11	0,1092	13,49	11	0,2622	5,35	11	0,9133
18	23,64	17	0,194	15,58	17	0,2952	13,26	17	0,7189
24	28,49	23	0,198	24,95	23	0,3528	16,81	23	0,8184
30	34,42	29	0,2241	31,,79	29	0,3293	20,9	29	0,8627
36	37,75	35	0,3448	43,28	35	0,1507	24,32	35	0,9121

**Tabel 4.5 Uji Asumsi Independen Skenario 1 (lanjutan)**

Hingga Lag ke-	Replikasi 4			Replikasi 5		
	Uji White Noise			Uji White Noise		
	$\chi^2$	Df	P-value	$\chi^2$	Df	P-value
6	1,22	5	0,9432	1,97	5	0,8531
12	4,45	11	0,9547	3,82	11	0,975
18	5,44	17	0,9962	6	17	0,9909
24	11,6	23	0,9762	9,53	23	0,9938
30	15,53	29	0,9805	14,3	29	0,9897
36	25,17	35	0,8898	24,3	35	0,9126

Tahap selanjutnya adalah membentuk model ARIMAX yakni gabungan antara model ARIMA dan model regresi *time series* kemudian diestimasi secara simultan pada Lampiran 10 hingga 14.

a. Model ARIMAX untuk replikasi satu

$$\begin{aligned}
 Z_t = & 0,29t + 8,72M_{1,t} + 10,89M_{2,t} + 14,57M_{3,t} + 23,23M_{4,t} + 25,53M_{5,t} \\
 & + 28,03M_{6,t} + 30,20M_{7,t} + 26,21M_{8,t} + 25,01M_{9,t} + 23,47M_{10,t} \\
 & + 16,72M_{11,t} + 12,58M_{12,t} + 5,23D_{1,t} + 23,48D_{2,t} + 50,62D_{3,t} \\
 & + 69,34D_{4,t} + 39,69D_{1,t-1} + 29,70D_{2,t-1} + 25,42D_{3,t-1} + 20,34D_{4,t-1} \\
 & + \frac{1}{(1-0,623B)} a_t
 \end{aligned}$$

b. Model ARIMAX untuk replikasi dua

$$\begin{aligned}
 Z_t = & 0,29t + 8,41M_{1,t} + 10,47M_{2,t} + 14,41M_{3,t} + 23,30M_{4,t} + 25,94M_{5,t} \\
 & + 28,39M_{6,t} + 30,81M_{7,t} + 26,30M_{8,t} + 24,54M_{9,t} + 22,42M_{10,t} \\
 & + 16,23M_{11,t} + 12,32M_{12,t} + 7,08D_{1,t} + 25,29D_{2,t} + 49,65D_{3,t} \\
 & + 69,97D_{4,t} + 40,63D_{1,t-1} + 30,40D_{2,t-1} + 24,67D_{3,t-1} + 20,05D_{4,t-1} \\
 & + \frac{1}{(1-0,728B)} a_t
 \end{aligned}$$

## c. Model ARIMAX untuk replikasi tiga

$$\begin{aligned}
Z_t = & 0,30t + 7,83M_{1,t} + 9,72M_{2,t} + 13,98M_{3,t} + 22,40M_{4,t} + 24,50M_{5,t} \\
& + 28,17M_{6,t} + 30,47M_{7,t} + 27,04M_{8,t} + 24,81M_{9,t} + 22,63M_{10,t} \\
& + 15,66M_{11,t} + 12,07M_{12,t} + 7,08D_{1,t} + 25,29D_{2,t} + 49,65D_{3,t} \\
& + 69,97D_{4,t} + 40,96D_{1,t-1} + 30,40D_{2,t-1} + 24,67D_{3,t-1} + 20,05D_{4,t-1} \\
& + \frac{1}{(1 - 0,666B)} a_t
\end{aligned}$$

## d. Model ARIMAX untuk replikasi empat

$$\begin{aligned}
Z_t = & 0,30t + 7,43M_{1,t} + 10,12M_{2,t} + 13,88M_{3,t} + 22,74M_{4,t} + 24,78M_{5,t} \\
& + 28,17M_{6,t} + 29,50M_{7,t} + 24,99M_{8,t} + 24,04M_{9,t} + 21,76M_{10,t} \\
& + 15,58M_{11,t} + 11,83M_{12,t} + 4,39D_{1,t} + 25,08D_{2,t} + 50,10D_{3,t} \\
& + 69,70D_{4,t} + 40,11D_{1,t-1} + 30,22D_{2,t-1} + 24,50D_{3,t-1} + 20,72D_{4,t-1} \\
& + \frac{1}{(1 - 0,750B)} a_t
\end{aligned}$$

## e. Model ARIMAX untuk replikasi lima

$$\begin{aligned}
Z_t = & 0,30t + 7,67M_{1,t} + 9,72M_{2,t} + 13,54M_{3,t} + 23,05M_{4,t} + 25,40M_{5,t} \\
& + 28,27M_{6,t} + 29,82M_{7,t} + 26,27M_{8,t} + 24,38M_{9,t} + 22,15M_{10,t} \\
& + 15,07M_{11,t} + 11,43M_{12,t} + 4,86D_{1,t} + 24,47D_{2,t} + 50,05D_{3,t} \\
& + 70,96D_{4,t} + 40,86D_{1,t-1} + 29,36D_{2,t-1} + 25,00D_{3,t-1} + 19,52D_{4,t-1} \\
& + \frac{1}{(1 - 0,706B)} a_t
\end{aligned}$$

Selanjutnya dilakukan Uji Kolmogorov-Smirnov pada persamaan model ARIMAX replikasi satu. Hasil pengujian ini menyimpulkan bahwa residual sudah berdistribusi normal karena  $p$ -value lebih dari 0,05. Analisis selanjutnya adalah menghitung kebaikan model berdasarkan RMSE *out-sample* yang ditampilkan pada Tabel 4.6.

**Tabel 4.6** Akurasi Peramalan Model ARIMAX Skenario 1

Replikasi	RMSE	
	<i>In-sample</i>	<i>Out-Sample</i>
1	1,32848	1,49711
2	1,36645	2,18295
3	1,24990	2,22734
4	1,39489	2,06974
5	1,49629	2,89455



Setelah memenuhi asumsi independen dan berdistribusi normal maka dilakukan pengujian varians residual homogen dengan uji *Lagrange Multiplier* pada Tabel 4.7


**Tabel 4.7** Uji Heteroskedastisitas Model ARIMAX Skenario 1

<i>k</i>	<i>Chi-Sq</i>	<i>p-value</i>
1	1.1915	0.2750
2	2.5802	0.2752
3	2.5910	0.4591
4	2.8762	0.5787
5	3.1478	0.6772
6	4.4803	0.6120
7	5.5844	0.5890
8	5.5908	0.6930
9	5.9739	0.7425
10	6.0407	0.8118
11	6.2091	0.8591
12	6.5396	0.8865

Apabila varians tidak homogen maka akan dilanjutkan pemodelan ARCH. Berdasarkan Tabel 4.7, hasil pengujian *Lagrange Multiplier* untuk skenario satu, menunjukkan bahwa varians residual bersifat homogen karena dari lag 1 hingga 12 memiliki *p-value* lebih dari 0,05, sehingga bisa disimpulkan untuk skenario satu sudah memenuhi asumsi identik, independen, dan berdistribusi normal.

### **B. Neural Network Untuk Skenario 1**

Pada pemodelan *Neural Network* input yang digunakan adalah lag-lag yang keluar pada PACF dari data simulasi untuk skenario 1 dan variabel *dummy*. Berikut PACF untuk lima replikasi ditampilkan pada Gambar 4.3.



**Gambar 4.3** Plot PACF Replikasi (a) satu, (b) dua, (c) tiga, (d) empat, dan (e) lima Skenario 1

Pada Gambar 4.3, lag yang signifikan pada plot PACF adalah lag 1, lag 9, lag 10, lag 11, lag 12, dan lag 13. Sehingga input yang digunakan adalah  $Z_{t-1}, Z_{t-9}, Z_{t-10}, Z_{t-11}, Z_{t-12}$ , dan  $Z_{t-13}$ .

**Tabel 4.8** Uji Terasvirta Skenario 1

Replikasi	Chi-Sq	DF	p-value
1	557,7242	77	0,0000
2	489,9357	77	0,0000
3	566,8251	77	0,0000
4	514,6752	77	0,0000
5	486,6254	77	0,0000

Berdasarkan Tabel 4.8, hasil uji non-linieritas menggunakan uji Terasvirta menunjukkan hubungan yang non-linier karena *p-value* kurang dari 0,05. Sehingga input yang digunakan adalah  $Z_{t-1}, Z_{t-9}, Z_{t-10}, Z_{t-11}, Z_{t-12}$ , dan  $Z_{t-13}$ . Kemudian dilakukan kombinasi *hidden neuron* yaitu 1, 2, 3, 4, 5, 10, dan 15 *neuron*. Berikut akurasi peramalan menggunakan *Neural Network* pada Tabel 4.9.

**Tabel 4.9** Akurasi Peramalan Model *Neural Network* dengan Input Lag Skenario 1

<i>Hidden Neuron</i>	Replikasi 1		Replikasi 2		Replikasi 3	
	RMSE		RMSE		RMSE	
	<i>In-sample</i>	<i>Out-sample</i>	<i>In-sample</i>	<i>Out-sample</i>	<i>In-sample</i>	<i>Out-sample</i>
1	8,630	18,235	8,585	<b>17,485</b>	8,587	20,101
2	7,399	<b>18,208</b>	7,513	17,927	7,394	19,080
3	7,577	20,417	7,332	17,510	7,479	19,636
4	7,429	18,914	6,007	20,086	6,812	19,411
5	8,017	19,621	7,177	20,280	7,625	<b>18,535</b>
10	7,413	20,981	6,629	20,078	6,433	19,639
15	7,017	21,667	5,637	19,327	6,427	21,228

**Tabel 4.9** Akurasi Peramalan Model *Neural Network* dengan Input Lag Skenario 1 (lanjutan)

<i>Hidden Neuron</i>	Replikasi 4		Replikasi 5	
	RMSE		RMSE	
	<i>In-sample</i>	<i>Out-sample</i>	<i>In-sample</i>	<i>Out-sample</i>
1	8,862	18,356	8,959	21,633
2	8,114	18,810	7,717	21,620
3	7,407	<b>17,498</b>	8,403	<b>21,130</b>
4	7,501	18,787	7,439	21,663
5	7,434	19,275	7,491	24,222
10	7,878	19,844	8,117	21,744
15	7,615	19,723	7,878	22,185

Berdasarkan Tabel 4.9, nilai RMSE *out-sample* terkecil pada replikasi ke satu dengan jumlah *hidden 2 neuron*, kemudian pada replikasi ke dua dengan jumlah *hidden 1 neuron*, pada replikasi ke tiga dengan jumlah *hidden 5 neuron*, lalu pada replikasi ke empat dan lima dengan jumlah *hidden 3 neuron* merupakan model yang terbaik. Kemudian akurasi peramalan menggunakan *Neural Network* dengan input lag dan variabel *dummy* ditampilkan pada Tabel 4.10.


**Tabel 4.10** Akurasi Peramalan Model *Neural Network* dengan Input Lag dan *Dummy* Skenario 1

<i>Hidden Neuron</i>	Replikasi 1		Replikasi 2		Replikasi 3	
	RMSE		RMSE		RMSE	
	<i>In-sample</i>	<i>Out-sample</i>	<i>In-sample</i>	<i>Out-sample</i>	<i>In-sample</i>	<i>Out-sample</i>
1	5,264	20,483	5,818	<b>19,701</b>	5,3575	20,843
2	4,676	20,955	4,774	20,402	5,1525	21,754
3	4,717	22,377	5,449	20,189	4,0458	22,452
4	4,614	21,517	5,082	20,704	4,8572	21,503
5	4,279	21,265	4,073	20,967	4,2364	22,163
10	3,555	<b>20,340</b>	2,882	21,035	3,1818	<b>20,755</b>
15	3,021	21,387	3,167	23,67	2,7111	22,293

**Tabel 4.10** Akurasi Peramalan Model *Neural Network* dengan Input Lag dan *Dummy* Skenario 1 (lanjutan)

Hidden Neuron	Replikasi 4		Replikasi 5	
	RMSE		RMSE	
	In-sample	Out-sample	In-sample	Out-sample
1	5,140	21,066	5,518	<b>23,026</b>
2	5,348	21,003	5,670	24,251
3	4,787	21,396	5,050	23,619
4	4,146	21,772	4,318	23,440
5	4,676	<b>19,977</b>	5,206	23,350
10	3,245	21,819	3,151	23,798
15	3,305	22,465	3,224	23,041

Berdasarkan Tabel 4.10, nilai RMSE *out-sample* terkecil pada replikasi ke satu dan tiga dengan jumlah *hidden* 10 *neuron*, kemudian pada replikasi ke dua dan lima dengan jumlah *hidden* 1 *neuron*, serta pada replikasi ke empat dengan jumlah *hidden* 5 *neuron* merupakan model yang terbaik. Namun secara keseluruhan, jika dilihat dari RMSE *out-sample* untuk input lag memiliki nilai RMSE lebih kecil dibandingkan input variabel *dummy*. Sehingga pada skenario 1 menggunakan input lag sebagai model terbaik. Berikut arsitektur FFN model terbaik pada setiap replikasi ditampilkan pada Gambar 4.4.



**Gambar 4.4** Arsitektur FFNN model terbaik (a) satu, (b) dua, (c) tiga, (d) empat, dan (e) lima Skenario 1

### C. *Hybrid* ARIMAX-NN Untuk Skenario 1

*Hybrid* ARIMAX-NN merupakan gabungan dari model linier yaitu ARIMAX dan model non-linier yaitu NN. Tahapan awal dalam melakukan *hybrid* ARIMAX-NN adalah mendapatkan model ARIMAX, kemudian residual dari ARIMAX akan dimodelkan dengan menggunakan model non linier yaitu *Neural Network*. Input yang digunakan dalam memodelkan *hybrid* ARIMAX-NN berdasarkan model AR pada ARIMAX yang didapatkan pada subab sebelumnya. Berdasarkan subab sebelumnya, model AR pada ARIMAX yang diperoleh adalah AR(1) pada replikasi 1, sehingga input yang digunakan pada *hybrid* ARIMAX-NN adalah  $Z_{t-1}$ . Kemudian dilakukan kombinasi *hidden neuron* yaitu 1, 2, 3, 4, 5, 10, dan 15 *neuron*. Kemudian akan dihitung akurasi peramalan menggunakan *hybrid* ARIMAX-NN pada Tabel 4.11. Berdasarkan Tabel 4.11, nilai RMSE *out-sample* terkecil pada replikasi ke satu dan lima dengan jumlah *hidden* 1 *neuron*, kemudian pada replikasi ke dua dan empat dengan jumlah *hidden* 3 *neuron*, serta pada replikasi ke tiga dengan jumlah *hidden* 4 *neuron* merupakan model yang terbaik.


**Tabel 4.11** Akurasi Peramalan Model *Hybrid* ARIMAX-NN Skenario 1

<i>Hidden Neuron</i>	Replikasi 1		Replikasi 2		Replikasi 3	
	RMSE		RMSE		RMSE	
	<i>In-sample</i>	<i>Out-sample</i>	<i>In-sample</i>	<i>Out-sample</i>	<i>In-sample</i>	<i>Out-sample</i>
1	1,318	<b>1,489</b>	3,119	2,012	1,248	2,225
2	1,308	1,499	3,141	1,987	1,246	2,254
3	1,308	1,491	3,141	<b>1,924</b>	1,237	2,319
4	1,308	1,492	3,130	2,009	1,252	<b>2,221</b>
5	1,322	1,499	3,140	1,958	1,246	2,257
10	1,307	1,500	3,134	2,026	1,247	2,257
15	1,307	1,496	3,085	2,060	1,246	2,243

**Tabel 4.11** Akurasi Peramalan Model *Hybrid* ARIMAX-NN Skenario 1 (lanjutan)

Hidden Neuron	Replikasi 4		Replikasi 5	
	RMSE		RMSE	
	In-sample	Out-sample	In-sample	Out-sample
1	1,395	2,062	1,497	<b>2,881</b>
2	1,394	2,059	1,494	2,893
3	1,394	<b>2,053</b>	1,494	2,904
4	1,394	2,055	1,492	2,934
5	1,395	2,059	1,493	2,933
10	1,394	2,062	1,493	2,926
15	1,394	2,053	1,488	2,959

Berikut arsitektur model terbaik pada setiap replikasi ditampilkan pada Gambar 4.5.



**Gambar 4.5** Arsitektur model terbaik Replikasi (a) satu, (b) dua, (c) tiga, (d) empat, dan (e) lima Skenario 1

Kemudian dilakukan pengujian varians residual homogen dengan uji *Lagrange Multiplier* pada Tabel 4.12.

**Tabel 4.12** Uji Heteroskedastisitas Model *Hybrid* ARIMAX-NN Skenario 1

<i>k</i>	<i>Chi-Sq</i>	<i>p-value</i>
1	1.05880	0.30349
2	2.53312	0.28180
3	2.38758	0.49595
4	2.98675	0.56005
5	3.07442	0.68851
6	4.39335	0.62361
7	5.48664	0.60080
8	5.75711	0.67442
9	5.99014	0.74091
10	5.95148	0.81932
11	5.88612	0.88085
12	6.50438	0.88856

Apabila varians tidak homogen maka akan dilanjutkan pemodelan ARCH. Berdasarkan Tabel 4.12, hasil pengujian *Lagrange Multiplier* untuk replikasi pertama, menunjukkan bahwa varians residual sudah homogen karena dari lag 1 hingga 12 memiliki *p-value* lebih dari 0,05.

#### 4.1.2 Skenario 2

Pada skenario 2 membangkitkan data bulanan Januari 2001 hingga Desember 2016 yang bersifat homogen dan mengikuti proses *Exponential Smooth Transition Autoregressive* (ESTAR-2). Diberikan persamaan untuk setiap masing-masing komponen kemudian dilakukan replikasi sebanyak lima kali. Setiap replikasi dibedakan dengan membangkitkan  $a_t$  sebanyak lima kali. Berikut persamaan untuk setiap masing-masing komponen.


$$T_t = 0,3t$$

$$CV_t = 40D_{1,t-1} + 30D_{2,t-2} + 25D_{3,t-3} + 20D_{4,t-4} + 5D_{1,t} + 25D_{2,t} + 50D_{3,t} + 70D_{4,t}$$

$$S_t = 8M_{1,t} + 10M_{2,t} + 14M_{3,t} + 23M_{4,t} + 25M_{5,t} + 28M_{6,t} + 30M_{7,t} + 26M_{8,t} + 24M_{9,t} + 22M_{10,t} + 16M_{11,t} + 12M_{12,t}$$

$$N_t = 6,5N_{t-1} \exp(-0,25N_{t-1}^2) + a_t \text{ . dengan } a_t \sim N(0, 2)$$

Kemudian dilakukan *time series plot* dan *box plot* untuk replikasi pertama pada skenario 2.



**Gambar 4.6** (a) *Time Series Plot* Data Simulasi Replikasi Pertama, (b) *Scatter Plot* untuk Komponen Residual dengan Lag 1, (c) *Box Plot* Data Simulasi, dan (d) *Box Plot* Data Simulasi Tanpa Tren Skenario 2

Berdasarkan Gambar 4.6 (a) menunjukkan adanya pola tren, pola musiman, dan pola variasi kalender hari raya Idul Fitri. Namun pada Gambar 4.6 (b). terlihat pada komponen residual pada lag 1 memiliki pola hubungan yang non-linier. Jika dilihat dari *box plot* pada Gambar 4.6 (c) dan (d) pada bulan hari raya dan bulan sebelum hari raya Idul Fitri cenderung lebih tinggi jika dibandingkan dengan bulan-bulan biasa. Kemudian akan dianalisis menggunakan metode ARIMAX, NN dan *Hybrid ARIMAX-NN*.



## A. ARIMAX Untuk Skenario 2

Tahap awal pembentukan model ARIMAX adalah mengacu pada pemodelan regresi *time series* sebagai berikut.

$$\begin{aligned}
 Z_t = & \delta t + \beta_1 M_{1,t} + \beta_2 M_{2,t} + \beta_3 M_{3,t} + \beta_4 M_{4,t} + \beta_5 M_{5,t} + \beta_6 M_{6,t} + \beta_7 M_{7,t} \\
 & + \beta_8 M_{8,t} + \beta_9 M_{9,t} + \beta_{10} M_{10,t} + \beta_{11} M_{11,t} + \beta_{12} M_{12,t} + \gamma_1 D_{1,t} + \gamma_2 D_{2,t} \\
 & + \gamma_3 D_{3,t} + \gamma_4 D_{4,t} + \alpha_1 D_{1,t-1} + \alpha_2 D_{2,t-1} + \alpha_3 D_{3,t-1} + \alpha_4 D_{4,t-1} + a_t
 \end{aligned}$$

Kemudian dilakukan estimasi parameter pada Tabel 4.13, hasil signifikansi parameter pada Tabel 4.13 diperoleh parameter yang sudah signifikan dikarenakan *p-value* kurang dari  $\alpha$  (0,05). Persamaan regresi *time series* untuk replikasi ke satu sebagai berikut.

$$\begin{aligned}
 Z_t = & 0,294t + 9,65M_{1,t} + 9,93M_{2,t} + 14,90M_{3,t} + 23,48M_{4,t} + 25,20M_{5,t} \\
 & + 26,78M_{6,t} + 28,3M_{7,t} + 25,3M_{8,t} + 25,2M_{9,t} + 22,9M_{10,t} + 16M_{11,t} \\
 & + 12,58M_{12,t} + 6,17D_{1,t} + 22,9D_{2,t} + 52,9D_{3,t} + 68,85D_{4,t} + 37,15D_{1,t-1} \\
 & + 27,21D_{2,t-1} + 27,04D_{3,t-1} + 19,72D_{4,t-1} + a_t
 \end{aligned}$$

**Tabel 4.13** Estimasi Parameter Regresi *Time Series* Replikasi Satu

Parameter	Estimasi	Standar Error	t-value	P-value
$\delta$	0,294	0,004	59,53	<0,0001
$\beta_1$	9,652	0,973	9,91	<0,0001
$\beta_2$	9,932	0,975	10,18	<0,0001
$\beta_3$	14,90	0,978	15,24	<0,0001
$\beta_4$	23,48	0,980	23,96	<0,0001
$\beta_5$	25,20	0,982	25,66	<0,0001
$\beta_6$	26,78	0,996	26,89	<0,0001
$\beta_7$	28,95	1,021	28,33	<0,0001
$\beta_8$	25,31	1,024	24,71	<0,0001
$\beta_9$	25,26	1,037	24,37	<0,0001
$\beta_{10}$	22,92	1,059	21,64	<0,0001
$\beta_{11}$	16,13	1,050	15,36	<0,0001
$\beta_{12}$	12,58	1,018	12,36	<0,0001
$\gamma_1$	6,178	2,051	3,01	<0,0001
$\gamma_2$	23,934	1,777	13,46	<0,0001
$\gamma_3$	52,977	1,772	29,89	<0,0001
$\gamma_4$	68,859	1,777	38,74	<0,0001
$\alpha_1$	37,157	2,057	18,06	<0,0001
$\alpha_2$	27,219	1,777	15,31	<0,0001
$\alpha_3$	27,045	1,772	15,26	<0,0001
$\alpha_4$	19,724	1,772	11,13	<0,0001

Persamaan pada model regresi *time series* untuk replikasi satu hingga replikasi lima menghasilkan residual yang belum *white noise* yang berarti residual mengandung autokorelasi karena *p-value* yang kurang dari 0,05 pada lag 6 hingga lag 36. Hal ini ditampilkan pada Tabel 4.14.


**Tabel 4.14** Uji Asumsi *White Noise* Residual Regresi *Time Series* Skenario 2

Hingga Lag ke-	Replikasi 1			Replikasi 2			Replikasi 3		
	Uji <i>White Noise</i>			Uji <i>White Noise</i>			Uji <i>White Noise</i>		
	$\chi^2$	df	P-value	$\chi^2$	df	P-value	$\chi^2$	df	P-value
6	27,18	6	0,0001	79,5	6	<0,0001	22,05	6	0,0001
12	33,5	12	0,0008	82,41	12	<0,0001	23,77	12	0,0219
18	37,87	18	0,0040	93,16	18	<0,0001	34,23	18	0,0118
24	58,04	24	0,0001	96,99	24	<0,0001	45,84	24	0,0046
30	81,68	30	<0,0001	98,42	30	<0,0001	51,97	30	0,0077
36	84,8	36	<0,0001	106,74	36	<0,0001	58,52	36	0,0102

**Tabel 4.14** Uji Asumsi *White Noise* Residual Regresi *Time Series* Skenario 2 (lanjutan)

Hingga Lag ke-	Replikasi 4			Replikasi 5		
	Uji <i>White Noise</i>			Uji <i>White Noise</i>		
	$\chi^2$	df	P-value	$\chi^2$	df	P-value
6	23,82	6	0,0006	19,82	6	0,0006
12	32,28	12	0,0013	33,01	12	0,0013
18	39,78	18	0,0022	38,84	18	0,0022
24	47,62	24	0,0028	41,18	24	0,0028
30	52,89	30	0,0061	42,22	30	0,0061
36	58,46	36	0,0104	44,77	36	0,0104

Kemudian tahap pertama yang dilakukan ketika residual belum *white noise* adalah pembentukan model ARIMA berdasarkan plot ACF dan PACF residual regresi *time series* guna mendapatkan model yang memenuhi asumsi independen yang ditampilkan pada Gambar 4.7.



**Gambar 4.7** Plot ACF dan PACF Residal Regresi *Time Series* Replikasi Satu

Berdasarkan Gambar 4.7, plot PACF *cut off* setelah lag 1 serta ACF membentuk pola *dies down* sehingga model ARIMA yang dapat dibentuk adalah model ARIMA (1,0,0). Hasil estimasi parameter ditampilkan pada Tabel 4.15 yang menunjukkan semua parameter signifikan *karena p-value* yang kurang dari 0,05 serta menghasilkan residual yang independen yang ditampilkan pada Tabel 4.16, karena tidak ada *p-value* yang kurang dari 0,05.

**Tabel 4.15** Estimasi Parameter dan Uji signifikansi Parameter ARIMA Skenario 2

Replikasi	Model	Parameter	Estimasi	t-value	P-value	Keterangan
1	ARIMA(1,0,0)	$\phi_1$	0,35469	5,06	<.0001	Signifikan
2	ARIMA(2,0,0)	$\phi_1$	0,28342	3,97	0,0001	Signifikan
		$\phi_2$	0,30996	4,33	<.0001	Signifikan
3	ARIMA(1,0,0)	$\phi_1$	0,32706	4,62	<.0001	Signifikan
4	ARIMA(1,0,0)	$\phi_1$	0,3244	4,49	<.0001	Signifikan
5	ARIMA(1,0,0)	$\phi_1$	0,3088	4,31	<.0001	Signifikan

**Tabel 4.16** Uji Asumsi Independen Skenario 2

Hingga Lag ke-	Replikasi 1			Replikasi 2			Replikasi 3		
	Uji White Noise			Uji White Noise			Uji White Noise		
	$\chi^2$	df	P-value	$\chi^2$	df	P-value	$\chi^2$	Df	P-value
6	0,69	5	0,9834	1,23	5	0,8735	0,64	5	0,9862
12	9,82	11	0,5463	3,59	11	0,964	2,54	11	0,9955
18	18,42	17	0,3629	12,75	17	0,6912	10,68	17	0,8729
24	29,88	23	0,1529	21,94	23	0,4632	22,14	23	0,5119
30	41,06	29	0,068	23,55	29	0,7049	28,71	29	0,4805
36	45	35	0,119	35,13	35	0,4145	33,25	35	0,5528

**Tabel 4.16** Uji Asumsi Independen Skenario 2 (lanjutan)

Hingga Lag ke-	Replikasi 4			Replikasi 5		
	Uji White Noise			Uji White Noise		
	df	P-value		df	P-value	
6	1,77	5	0,8806	1,7	5	0,8891
12	7,68	11	0,7416	13,53	11	0,2599
18	13,35	17	0,7124	16	17	0,5235
24	20,2	23	0,6300	18,06	23	0,7541
30	26,24	29	0,6127	19,21	29	0,9157
36	31,22	35	0,6513	22,34	35	0,9521

Tahap selanjutnya adalah membentuk model ARIMAX yakni gabungan antara model ARIMA dan model regresi *time series* kemudian diestimasi secara simultan pada Lampiran 15 hingga 19.

a. Model ARIMAX untuk replikasi satu

$$\begin{aligned} Z_t = & 0,29t + 9,65M_{1,t} + 9,92M_{2,t} + 14,89M_{3,t} + 23,46M_{4,t} + 25,185M_{5,t} \\ & + 26,73M_{6,t} + 28,88M_{7,t} + 25,239M_{8,t} + 25,239M_{9,t} + 22,978M_{10,t} \\ & + 16,21M_{11,t} + 12,585M_{12,t} + 4,511D_{1,t} + 24,626D_{2,t} + 52,847D_{3,t} \\ & + 69,088D_{4,t} + 35,966D_{1,t-1} + 27,266D_{2,t-1} + 26,93D_{3,t-1} + 20,32D_{4,t-1} \\ & + \frac{1}{(1-0,374B)} a_t \end{aligned}$$

b. Model ARIMAX untuk replikasi dua

$$\begin{aligned} Z_t = & 0,298t + 7,914M_{1,t} + 9,92M_{2,t} + 13,42M_{3,t} + 22,43M_{4,t} + 24,83M_{5,t} \\ & + 28,074M_{6,t} + 30,626M_{7,t} + 25,792M_{8,t} + 23,517M_{9,t} + 22,375M_{10,t} \\ & + 14,837M_{11,t} + 11,975M_{12,t} + 4,658D_{1,t} + 28,593D_{2,t} + 49,787D_{3,t} \\ & + 72,290D_{4,t} + 39,213D_{1,t-1} + 32,119D_{2,t-1} + 28,123D_{3,t-1} + 20,217D_{4,t-1} \\ & + \frac{1}{(1-0,286B-0,359B^2)} a_t \end{aligned}$$

c. Model ARIMAX untuk replikasi tiga

$$\begin{aligned} Z_t = & 0,3t + 6,597M_{1,t} + 8,916M_{2,t} + 13,65M_{3,t} + 22,56M_{4,t} + 25,39M_{5,t} \\ & + 26,103M_{6,t} + 29,053M_{7,t} + 24,895M_{8,t} + 23,956M_{9,t} + 23,38M_{10,t} \\ & + 15,527M_{11,t} + 12,964M_{12,t} + 3,780D_{1,t} + 24,076D_{2,t} + 51,126D_{3,t} \\ & + 68,60D_{4,t} + 38,447D_{1,t-1} + 32,50D_{2,t-1} + 26,53D_{3,t-1} + 19,416D_{4,t-1} \\ & + \frac{1}{(1-0,343B)} a_t \end{aligned}$$

d. Model ARIMAX untuk replikasi empat

$$\begin{aligned} Z_t = & 0,29t + 7,95M_{1,t} + 8,63M_{2,t} + 13,88M_{3,t} + 21,99M_{4,t} + 24,60M_{5,t} \\ & + 27,881M_{6,t} + 30,761M_{7,t} + 25,964M_{8,t} + 24,521M_{9,t} + 21,59M_{10,t} \\ & + 15,467M_{11,t} + 11,829M_{12,t} + 5,173D_{1,t} + 26,857D_{2,t} + 52,219D_{3,t} \\ & + 68,537D_{4,t} + 40,289D_{1,t-1} + 27,474D_{2,t-1} + 24,605D_{3,t-1} + 20,66D_{4,t-1} \\ & + \frac{1}{(1-0,340B)} a_t \end{aligned}$$

e. Model ARIMAX untuk replikasi lima

$$\begin{aligned}
 Z_t = & 0,294t + 7,618M_{1,t} + 9,434M_{2,t} + 14,485M_{3,t} + 23,643M_{4,t} + 25,447M_{5,t} \\
 & + 28,865M_{6,t} + 30,833M_{7,t} + 29,412M_{8,t} + 24,882M_{9,t} + 22,159M_{10,t} \\
 & + 16,814M_{11,t} + 11,462M_{12,t} + 5,519D_{1,t} + 22,263D_{2,t} + 51,593D_{3,t} \\
 & + 68,759D_{4,t} + 38,938D_{1,t-1} + 25,908D_{2,t-1} + 25,596D_{3,t-1} + 17,696D_{4,t-1} \\
 & + \frac{1}{(1-0,329B)} a_t
 \end{aligned}$$

Selanjutnya dilakukan Uji Kolmogorov-Smirnov pada persamaan model ARIMAX dengan replikasi satu. Hasil pengujian ini menyimpulkan bahwa residual sudah berdistribusi normal karena  $p$ -value lebih dari 0,05 dengan nilai  $D = 0,0443$ . Analisis selanjutnya adalah menghitung kebaikan model berdasarkan RMSE *out-sample* yang ditampilkan pada Tabel 4.17.

**Tabel 4.17** Akurasi Peramalan Model ARIMAX Skenario 2

Replikasi	RMSE	
	<i>In-sample</i>	<i>Out-Sample</i>
1	2,97837	4,13822
2	2,80919	4,7754
3	2,93121	2,7107
4	3,08511	3,43343
5	3,11508	3,58366


Setelah memenuhi asumsi independen dan berdistribusi normal maka dilakukan pengujian varians residual homogen dengan uji *Lagrange Multiplier*. Apabila varians tidak homogen maka akan dilanjutkan pemodelan ARCH. Hasil pengujian *Lagrange Multiplier* ditampilkan pada Tabel 4.18 untuk replikasi pertama, hasil tersebut menunjukkan bahwa varians residual telah homogen karena semua  $p$ -value lebih dari 0,05. Sehingga bisa disimpulkan bahwa model ARIMAX dengan variasi kalender untuk Skenario 2 telah memenuhi asumsi identik, independen, dan berdistribusi normal.

**Tabel 4.18** Uji Heteroskedastisitas Model ARIMAX Skenario 2

<i>K</i>	<i>Chi-Sq</i>	<i>p-value</i>
1	0,480114	0,488371
2	0,492614	0,781682
3	1,242297	0,742879
4	2,690945	0,6108
5	8,196648	0,145726
6	8,425392	0,208564
7	9,941302	0,191924
8	9,880242	0,273532
9	12,4083	0,191257
10	14,00204	0,172899
11	14,71356	0,19599
12	14,97831	0,242625

## B. Neural Network Untuk Skenario 2

Pada pemodelan *Neural Network* input yang digunakan adalah lag-lag yang keluar pada PACF dari data simulasi untuk skenario 1 dan variabel *dummy*. Berikut PACF untuk lima replikasi ditampilkan pada Gambar 4.10.

**Gambar 4.8** Plot PACF Replikasi (a) satu, (b) dua, (c) tiga, (d) empat, dan (e) lima Skenario 2

Pada Gambar 4.8, lag yang signifikan pada plot PACF adalah lag lag 1, lag 11, lag 12, dan lag 13. Sehingga input yang digunakan adalah  $Z_{t-1}, Z_{t-11}, Z_{t-12},$  dan  $Z_{t-13}$ . Kemudian dilakukan pengujian hubungan antar variabel dengan uji Terasvirta diperoleh sebagai berikut pada Tabel 4.19.

**Tabel 4.19** Uji Terasvirta Skenario 2

Replikasi	Chi-Sq	DF	p-value
1	228,9195	30	0,0000
2	214,9583	30	0,0000
3	200,6853	30	0,0000
4	199,3408	30	0,0000
5	220,8938	30	0,0000

Berdasarkan Tabel 4.19, hasil uji non-linieritas menggunakan uji Terasvirta menunjukkan hubungan yang non-linier karena  $p$ -value kurang dari 0,05. Sehingga input yang digunakan adalah  $Z_{t-1}$ ,  $Z_{t-11}$ ,  $Z_{t-12}$ , dan  $Z_{t-13}$ . Kemudian dilakukan kombinasi *hidden neuron* yaitu 1, 2, 3, 4, 5, 10, dan 15 *neuron*. Berikut akurasi peramalan menggunakan *Neural Network* pada Tabel 4.20.

**Tabel 4.20** Akurasi Peramalan Model *Neural Network* dengan Input Lag Skenario 2

Hidden Neuron	Replikasi 1		Replikasi 2		Replikasi 3	
	RMSE		RMSE		RMSE	
	In-sample	Out-sample	In-sample	Out-sample	In-sample	Out-sample
1	9,867	18,763	9,708	<b>19,080</b>	9,501	22,088
2	9,470	<b>15,442</b>	9,251	21,730	9,204	19,127
3	9,228	19,334	9,112	20,777	8,850	20,336
4	9,512	20,035	8,449	20,956	9,239	20,675
5	9,310	17,486	9,396	22,098	9,088	21,297
10	9,289	17,957	8,582	19,854	9,194	19,328
15	8,949	18,274	9,108	20,890	8,877	<b>18,514</b>

**Tabel 4.20** Akurasi Peramalan Model *Neural Network* dengan Input Lag Skenario 2 (lanjutan)

Hidden Neuron	Replikasi 4		Replikasi 5	
	RMSE		RMSE	
	In-sample	Out-sample	In-sample	Out-sample
1	9,808	20,824	9,722	20,302
2	9,534	<b>16,405</b>	9,058	22,570
3	8,292	19,525	9,087	22,744
4	9,325	18,124	9,357	21,132
5	9,283	19,198	8,479	20,666
10	9,147	18,481	8,813	21,670
15	9,115	20,789	9,111	<b>19,939</b>

Berdasarkan Tabel 4.20, nilai RMSE *out-sample* terkecil pada replikasi ke satu dan empat dengan *hidden 2 neuron*, kemudian pada replikasi ke dua dengan *hidden 1 neuron*, pada replikasi ke tiga dan lima dengan *hidden 15 neuron* merupakan model yang terbaik. Kemudian akurasi peramalan menggunakan *Neural*

*Network* dengan input lag dan variabel *dummy* ditampilkan pada Tabel 4.21.

**Tabel 4.21** Akurasi Peramalan Model *Neural Network* dengan Input Lag dan *Dummy* Skenario 2


<i>Hidden Neuron</i>	Replikasi 1		Replikasi 2		Replikasi 3	
	RMSE		RMSE		RMSE	
	<i>In-sample</i>	<i>Out-sample</i>	<i>In-sample</i>	<i>Out-sample</i>	<i>In-sample</i>	<i>Out-sample</i>
1	6,0073	20,3942	6,5600	21,4915	6,4055	20,7825
2	5,6784	20,9834	6,5499	22,2417	5,2070	21,1954
3	5,6600	21,1092	5,9369	<b>20,9778</b>	4,8358	22,5433
4	5,6434	<b>19,0232</b>	5,0070	22,6803	5,1667	23,1015
5	5,5491	21,8066	5,8185	21,4066	5,7756	<b>20,1277</b>
10	4,6199	22,7542	4,5527	21,3924	3,9307	22,0723
15	3,2550	22,7075	4,0377	22,3043	3,8098	21,1306

**Tabel 4.21** Akurasi Peramalan Model *Neural Network* dengan Input Lag dan *Dummy* Skenario 2 (lanjutan)

<i>Hidden Neuron</i>	Replikasi 4		Replikasi 5	
	RMSE		RMSE	
	<i>In-sample</i>	<i>Out-sample</i>	<i>In-sample</i>	<i>Out-sample</i>
1	6,5844	<b>20,7965</b>	6,3147	22,2331
2	5,9902	21,8819	6,0421	22,3009
3	5,4968	22,6734	5,3381	23,8660
4	5,2612	22,2689	4,8106	23,0208
5	5,6896	21,3328	5,3732	23,4048
10	4,1383	22,1532	3,9630	<b>22,1467</b>
15	4,0343	21,3209	4,3392	22,3639

Berdasarkan Tabel 4.21, nilai RMSE *out-sample* terkecil pada replikasi ke satu dengan *hidden 4 neuron*, kemudian pada replikasi ke dua dengan *hidden 3 neuron*, pada replikasi ke tiga dengan *hidden 5 neuron*, lalu pada replikasi empat dengan *hidden 1 neuron*, dan replikasi lima dengan jumlah *hidden 10 neuron* merupakan model yang terbaik. Namun secara keseluruhan, jika dilihat dari RMSE *out-sample* pada *Neural Network* dengan input lag saja dan input lag & *dummy* lebih bagus menggunakan input lag saja karena memiliki nilai RMSE *out-sample* yang lebih kecil dibandingkan input lag & *dummy*. Sehingga pada skenario 2 menggunakan input lag saja sebagai model terbaik. Berikut arsitektur FFNN model terbaik setiap replikasi ditampilkan pada Gambar 4.9.





**Gambar 4.9** Arsitektur FFN Model Terbaik (a) satu, (b) dua, (c) tiga, (d) empat, dan (e) lima Skenario 2

### C. Hybrid ARIMAX-NN Untuk Skenario 2

*Hybrid* ARIMAX-NN merupakan gabungan dari model linier yaitu ARIMAX dan model non-linier yaitu NN. Tahapan awal dalam melakukan *hybrid* ARIMAX-NN adalah mendapatkan model ARIMAX, kemudian residual dari ARIMAX akan dimodelkan dengan menggunakan model non linier yaitu *Neural Network*. Input yang digunakan dalam memodelkan *hybrid* ARIMAX-NN berdasarkan model AR pada ARIMAX yang diperoleh pada subab sebelumnya. Berdasarkan subab sebelumnya, model AR pada ARIMAX yang diperoleh adalah AR(1) pada replikasi 1, sehingga input yang digunakan pada *hybrid* ARIMAX-NN adalah  $Z_{t-1}$ . Kemudian dilakukan kombinasi *hidden neuron*

yaitu 1, 2, 3, 4, 5, 10, dan 15 *neuron*. Kemudian akan dihitung akurasi peramalan menggunakan *hybrid* ARIMAX-NN pada Tabel 4.22.

**Tabel 4.22** Akurasi Peramalan Model *Hybrid* ARIMAX-NN Skenario 2


<i>Hidden Neuron</i>	Replikasi 1		Replikasi 2		Replikasi 3	
	RMSE		RMSE		RMSE	
	<i>In-sample</i>	<i>Out-sample</i>	<i>In-sample</i>	<i>Out-sample</i>	<i>In-sample</i>	<i>Out-sample</i>
1	2,9755	<b>4,1203</b>	2,8244	4,7367	2,9380	2,7322
2	2,8846	4,3755	2,8833	4,7375	2,8315	2,9210
3	2,8725	4,3816	2,9997	4,7217	2,9386	2,7199
4	2,8729	4,3829	2,9593	<b>4,7129</b>	2,8773	2,6694
5	2,8441	4,4883	3,0461	4,7609	2,8578	2,6703
10	2,8640	4,4243	2,9094	4,7684	2,8589	<b>2,6665</b>
15	2,8568	4,3972	2,9695	4,7175	2,8149	2,7465

**Tabel 4.22** Akurasi Peramalan Model *Hybrid* ARIMAX-NN Skenario 2  
(lanjutan)

<i>Hidden Neuron</i>	Replikasi 4		Replikasi 5	
	RMSE		RMSE	
	<i>In-sample</i>	<i>Out-sample</i>	<i>In-sample</i>	<i>Out-sample</i>
1	3,0336	3,4154	3,1209	<b>3,5799</b>
2	2,7917	3,5597	3,1068	3,6204
3	2,8890	3,3867	3,0579	3,6724
4	2,9302	3,3969	2,9864	3,7679
5	2,9389	3,4016	3,0588	3,6603
10	2,9317	3,3970	3,0015	3,7428
15	2,9250	<b>3,3927</b>	3,0153	3,7471

Berdasarkan Tabel 4.22, nilai RMSE *out-sample* terkecil pada replikasi ke satu dan lima dengan *hidden* 1 *neuron*, kemudian pada replikasi ke dua dengan *hidden* 4 *neuron*, pada replikasi ke tiga dengan *hidden* 10 *neuron* serta pada replikasi lima dengan *hidden*

15 neuron merupakan model yang terbaik. Berikut arsitektur model terbaik pada setiap replikasi ditampilkan pada Gambar 4.10.



**Gambar 4.10** Arsitektur model terbaik Replikasi (a) satu, (b) dua, (c) tiga, (d) empat, dan (e) lima Skenario 2

Kemudian dilakukan pengujian varians residual homogen dengan uji *Lagrange Multiplier* pada Tabel 4.23.

**Tabel 4.23** Uji Heteroskedastisitas Model *Hybrid* ARIMAX-NN Skenario 2

$k$	$Chi-Sq$	$p-value$
1	0,685842	0,407582
2	0,6537	0,721192
3	1,483782	0,686019
4	2,911943	0,572668
5	8,316972	0,13961
6	8,559005	0,19994
7	10,00181	0,188471
8	9,960369	0,267819
9	12,3062	0,196593
10	14,03215	0,17153
11	14,5179	0,205648
12	14,94847	0,244267

Apabila varians tidak homogen maka akan dilanjutkan pemodelan ARCH. Berdasarkan Tabel 4.23, hasil pengujian *Lagrange Multiplier* untuk replikasi pertama, menunjukkan bahwa varians

residual homogen karena dari lag 1 hingga lag 12  $p$ -value lebih dari 0,05 .

### 4.1.3 Skenario 3

Pada skenario 3, membangkitkan data bulanan mulai dari Januari 2001 hingga Desember 2016 yang bersifat heterogen dan mengikuti model linier AR(1). Diberikan persamaan untuk setiap masing-masing komponen kemudian dilakukan replikasi sebanyak lima kali. Replikasi dibedakan dengan membangkitkan  $a_t$  sebanyak lima kali. Berikut persamaan untuk setiap masing-masing komponen.

$$T_t = 0,3t$$

$$S_t = \beta_1 M_{1,t} + \beta_2 M_{2,t} + \beta_3 M_{3,t} + \beta_4 M_{4,t} + \beta_5 M_{5,t} + \beta_6 M_{6,t} + \\ \beta_7 M_{7,t} + \beta_8 M_{8,t} + \beta_9 M_{9,t} + \beta_{10} M_{10,t} + \beta_{11} M_{11,t} + \beta_{12} M_{12,t}$$

dimana  $\beta_i \sim Uniform(a,b)$  . Berikut Tabel 4.26 merupakan penjelasan parameter untuk distribusi  $Uniform(a,b)$  disetiap bulannya.


**Tabel 4.24** Parameter Distribusi Uniform ( $a,b$ )

Bulan	Mean	A	b
Januari	8	1	17
Februari	10	2	22
Maret	14	0	28
April	23	0	46
Mei	25	1	51
Juni	28	1	57
Juli	30	20	80
Agustus	26	9	61
September	24	9	57
Oktober	22	0,5	44,5
November	16	4	36
Desember	12	2	26

$$CV_t = 40D_{1,t-1} + 30D_{2,t-2} + 25D_{3,t-3} + 20D_{4,t-4} + 5D_{1,t} + 25D_{2,t} + 50D_{3,t} + 70D_{4,t}$$

$$N_t = 0,7N_{t-1} + a_t, \text{ dengan } a_t \sim N(0,2.5)$$

Kemudian dilakukan *time series plot* dan *box plot* untuk replikasi ketiga pada skenario 3 pada Gambar 4.10.



**Gambar 4.11** (a) *Time Series Plot* Data Simulasi Replikasi Ketiga, (b) *Scatter Plot* untuk Komponen Residual dengan Lag 1, (c) *Box Plot* Data Simulasi, dan (d) *Box Plot* Data Simulasi tanpa Tren Skenario 3

Berdasarkan Gambar 4.11 (a) memiliki kesamaan pada Gambar 4.1 dan 4.6 (a) yaitu adanya pola tren, pola musiman, dan pola variasi kalender hari raya Idul Fitri. Namun perbedaannya pola data lebih menyebar dan jangkauan data terlihat rendah serta tinggi pada bulan tertentu di setiap tahunnya. Pada Gambar 4.11 (b), terlihat pada komponen residual pada lag 1 memiliki pola hubungan yang linier. Jika dilihat dari *box plot* pada Gambar 4.11 (c) dan (d) sebaran data tidak sama pada setiap bulannya sehingga terdapat varians yang cukup rendah serta varians yang cukup tinggi. Kemudian jika dilihat dari varians pada setiap bulannya, mengindikasikan bahwa data tersebut heterogen. Setelah itu, akan dianalisis menggunakan metode ARIMAX, *Neural Network*, dan *Hybrid ARIMAX-NN*.

### A. ARIMAX Untuk Skenario 3

Tahap awal pembentukan model ARIMAX adalah mengacu pada pemodelan regresi *time series*. Berikut persamaan regresi *time series* untuk replikasi ke tiga serta hasil estimasi parameter pada Tabel 4.25.

$$Z_t = 0,291t + 9,30M_{1,t} + 8,59M_{2,t} + 12,01M_{3,t} + 12,55M_{4,t} + 18,20M_{5,t} \\ + 11,59M_{11,t} + 18,78M_{6,t} + 21,85M_{7,t} + 19,56M_{8,t} + 20,99M_{9,t} \\ + 21,11M_{10,t} + 9,67M_{12,t} + 13,98D_{1,t} + 24,45D_{2,t} + 48,26D_{3,t} + 72D_{4,t} \\ + 40,72D_{1,t-1} + 24,46D_{2,t-1} + 26,59D_{3,t-1} + 19,22D_{4,t-1} + a_t$$

**Tabel 4.25** Estimasi Parameter Regresi *Time Series* Replikasi Tiga

Parameter	Estimasi	Standar Error	t-value	P-value
$\delta$	0.291	0.006	50.29	<.0001
$\beta_1$	9.304	1.140	8.16	<.0001
$\beta_2$	8.599	1.142	7.53	<.0001
$\beta_3$	12.019	1.145	10.5	<.0001
$\beta_4$	12.550	1.148	10.94	<.0001
$\beta_5$	18.205	1.150	15.83	<.0001
$\beta_6$	18.785	1.166	16.11	<.0001
$\beta_7$	21.857	1.196	18.27	<.0001
$\beta_8$	19.566	1.199	16.31	<.0001
$\beta_9$	20.995	1.214	17.3	<.0001
$\beta_{10}$	21.111	1.241	17.02	<.0001
$\beta_{11}$	11.590	1.230	9.42	<.0001
$\beta_{12}$	9.676	1.192	8.12	<.0001
$\gamma_1$	13.990	2.402	5.82	<.0001
$\gamma_2$	24.459	2.081	11.75	<.0001
$\gamma_3$	48.270	2.075	23.26	<.0001
$\gamma_4$	72.009	2.081	34.61	<.0001
$\alpha_1$	40.725	2.408	16.91	<.0001
$\alpha_2$	24.463	2.081	11.75	<.0001
$\alpha_3$	26.592	2.075	12.82	<.0001
$\alpha_4$	19.223	2.075	9.26	<.0001

Berdasarkan Tabel 4.25, uji signifikansi parameter pada model variasi kalender diperoleh parameter yang sudah signifikan dikarenakan  $p$ -value lebih kecil dari  $\alpha$  (0,05). Persamaan pada model regresi *time series* untuk replikasi satu hingga replikasi lima menghasilkan residual yang belum *white noise* karena  $p$ -value yang kurang dari 0,05 . Hal ini ditampilkan pada Tabel 4.26.


**Tabel 4.26** Uji Asumsi *White Noise* Residual Regresi *Time Series* Skenario 3

Hingga Lag ke-	Replikasi 1			Replikasi 2			Replikasi 3		
	Uji <i>White Noise</i>			Uji <i>White Noise</i>			Uji <i>White Noise</i>		
	$\chi^2$	df	P-value	$\chi^2$	Df	P-value	$\chi^2$	df	P-value
6	47,62	6	<0,0001	36,51	6	<0,0001	65,06	6	<0,0001
12	55,37	12	<0,0001	40,7	12	<0,0001	70,82	12	<0,0001
18	61,09	18	<0,0001	42,31	18	0,0010	81,8	18	<0,0001
24	69,23	24	<0,0001	48,55	24	0,0022	92,43	24	<0,0001
30	93,41	30	<0,0001	54,79	30	0,0038	95,6	30	<0,0001
36	109,31	36	<0,0001	85,16	36	<0,0001	103,55	36	<0,0001

**Tabel 4.26** Uji Asumsi *White Noise* Residual Regresi *Time Series* Skenario 3 (lanjutan)

Hingga Lag ke-	Replikasi 4			Replikasi 5		
	Uji <i>White Noise</i>			Uji <i>White Noise</i>		
	$\chi^2$	Df	P-value	$\chi^2$	df	P-value
6	53,55	6	<0,0001	50,83	6	<0,0001
12	61,9	12	<0,0001	54,38	12	<0,0001
18	63,72	18	<0,0001	61,12	18	<0,0001
24	74,09	24	<0,0001	67,79	24	<0,0001
30	79,56	30	<0,0001	73,89	30	<0,0001
36	92,27	36	<0,0001	94,05	36	<0,0001

Kemudian tahap pertama yang dilakukan ketika residual belum *white noise* adalah pembentukan model ARIMA berdasarkan plot ACF dan PACF residual regresi *time series* guna mendapatkan model yang memenuhi asumsi independen yang ditampilkan pada Gambar 4.12.



**Gambar 4.12** Plot ACF dan PACF Residual Regresi *Time Series* Replikasi Tiga

Berdasarkan Gambar 4.12, plot PACF *cut off* setelah lag 1 serta ACF membentuk pola *dies down* sehingga model yang diduga adalah ARIMA (1,0,0). Hasil estimasi parameter model ditampilkan pada tabel 4.27 yang menunjukkan semua parameter signifikan dikarenakan *p-value* kurang dari  $\alpha$  (0,05) serta menghasilkan residual yang independen ditampilkan pada Tabel 4.28.

**Tabel 4.27** Estimasi Parameter dan Uji signifikansi Parameter ARIMA Skenario 3

Replikasi	Model	Parameter	Estimasi	t-value	P-value	Keterangan
1	ARIMA(1,0,0)	$\phi_1$	0,4068	5,94	<,0001	Signifikan
2	ARIMA(1,0,0)	$\phi_1$	0,32489	4,59	<,0001	Signifikan
3	ARIMA(1,0,0)	$\phi_1$	0,47652	7,19	<,0001	Signifikan
4	ARIMA(1,0,0)	$\phi_1$	0,42619	6,25	<,0001	Signifikan
5	ARIMA(1,0,0)	$\phi_1$	0,37472	5,41	<,0001	Signifikan

**Tabel 4.28** Uji Asumsi Independen Skenario 3

Hingga Lag ke-	Replikasi 1			Replikasi 2			Replikasi 3		
	Uji White Noise			Uji White Noise			Uji White Noise		
	$\chi^2$	df	P-value	$\chi^2$	df	P-value	$\chi^2$	Df	P-value
6	7,65	5	0,1767	6,6	5	0,2525	5,73	5	0,3332
12	14,79	11	0,1922	12,63	11	0,3183	9,06	11	0,6165
18	19,03	17	0,327	14,91	17	0,6017	17,93	17	0,3931
24	27,2	23	0,2476	18,65	23	0,7216	23,32	23	0,4422
30	37,85	29	0,1258	24,85	29	0,6858	30,33	29	0,3976
36	48,11	35	0,069	43,26	35	0,1594	41,82	35	0,1988

**Tabel 4.28** Uji Asumsi Independen Skenario 3 (lanjutan)

Hingga Lag ke-	Replikasi 4			Replikasi 5		
	Uji White Noise			Uji White Noise		
	$\chi^2$	df	P-value	$\chi^2$	df	P-value
6	6,18	5	0,2891	8,87	5	0,1142
12	14,24	11	0,2202	14,12	11	0,2266
18	17,01	17	0,4537	21,08	17	0,2229
24	24,13	23	0,3965	27,67	23	0,2287
30	32,63	29	0,293	31,28	29	0,3523
36	44,69	35	0,1263	48,24	35	0,0673

Tahap selanjutnya adalah membentuk model ARIMAX yakni gabungan antara model ARIMA dan model regresi *time series* variasi kalender kemudian diestimasi secara simultan pada Lampiran 20 hingga 24.



a. Model ARIMAX untuk replikasi satu

$$\begin{aligned}
 Z_t = & 0,297t + 8,145M_{1,t} + 8,651M_{2,t} + 11,666M_{3,t} + 12,274M_{4,t} + 17,263M_{5,t} \\
 & + 18,623M_{6,t} + 21,367M_{7,t} + 18,386M_{8,t} + 19,028M_{9,t} + 18,919M_{10,t} \\
 & + 9,938M_{11,t} + 8,123M_{12,t} + 14,562D_{1,t} + 27,208D_{2,t} + 46,815D_{3,t} \\
 & + 7,134D_{4,t} + 43,098D_{1,t-1} + 27,863D_{2,t-1} + 23,428D_{3,t-1} + 17,268D_{4,t-1} \\
 & + \frac{1}{(1-0,417B)} a_t
 \end{aligned}$$

b. Model ARIMAX untuk replikasi dua

$$\begin{aligned}
 Z_t = & 0,312t + 7,501M_{1,t} + 6,841M_{2,t} + 10,924M_{3,t} + 11,083M_{4,t} + 15,990M_{5,t} \\
 & + 18,115M_{6,t} + 19,925M_{7,t} + 17,088M_{8,t} + 19,117M_{9,t} + 18,844M_{10,t} \\
 & + 8,876M_{11,t} + 7,558M_{12,t} + 15,301D_{1,t} + 24,866D_{2,t} + 48,028D_{3,t} \\
 & + 72,005D_{4,t} + 43,384D_{1,t-1} + 25,126D_{2,t-1} + 23,819D_{3,t-1} + 17,271D_{4,t-1} \\
 & + \frac{1}{(1-0,341B)} a_t
 \end{aligned}$$

c. Model ARIMAX untuk replikasi tiga

$$\begin{aligned}
 Z_t = & 0,292t + 8,954M_{1,t} + 8,383M_{2,t} + 11,869M_{3,t} + 12,432M_{4,t} + 18,103M_{5,t} \\
 & + 18,899M_{6,t} + 22,051M_{7,t} + 19,633M_{8,t} + 20,857M_{9,t} + 20,904M_{10,t} \\
 & + 11,460M_{11,t} + 9,437M_{12,t} + 14,713D_{1,t} + 25,373D_{2,t} + 47,420D_{3,t} \\
 & + 71,186D_{4,t} + 41,551D_{1,t-1} + 24,943D_{2,t-1} + 24,368D_{3,t-1} + 18,285D_{4,t-1} \\
 & + \frac{1}{(1-0,499B)} a_t
 \end{aligned}$$

d. Model ARIMAX untuk replikasi empat

$$\begin{aligned}
 Z_t = & 0,287t + 11,55M_{1,t} + 11,56M_{2,t} + 15,15M_{3,t} + 15,60M_{4,t} + 20,19M_{5,t} \\
 & + 21,03M_{6,t} + 24,09M_{7,t} + 21,97M_{8,t} + 23,97M_{9,t} + 24,43M_{10,t} \\
 & + 14,64M_{11,t} + 12,66M_{12,t} + 14,53D_{1,t} + 27,25D_{2,t} + 47,23D_{3,t} \\
 & + 70,83D_{4,t} + 41,49D_{1,t-1} + 25,43D_{2,t-1} + 24,11D_{3,t-1} + 18,22D_{4,t-1} \\
 & + \frac{1}{(1-0,437B)} a_t
 \end{aligned}$$

e. Model ARIMAX untuk replikasi lima

$$\begin{aligned}
 Z_t = & 0,297t + 8,145M_{1,t} + 8,651M_{2,t} + 11,666M_{3,t} + 12,274M_{4,t} + 17,263M_{5,t} \\
 & + 18,623M_{6,t} + 21,367M_{7,t} + 18,386M_{8,t} + 19,028M_{9,t} + 18,919M_{10,t} \\
 & + 9,938M_{11,t} + 8,123M_{12,t} + 14,562D_{1,t} + 27,208D_{2,t} + 46,815D_{3,t} \\
 & + 70,134D_{4,t} + 43,098D_{1,t-1} + 27,863D_{2,t-1} + 23,428D_{3,t-1} + 17,268D_{4,t-1} \\
 & + \frac{1}{(1-0,417B)}a_t
 \end{aligned}$$

Selanjutnya dilakukan Uji Kolmogorov-Smirnov pada persamaan model ARIMAX dengan replikasi tiga. Hasil pengujian ini menyimpulkan bahwa residual sudah berdistribusi normal karena  $p$ -value lebih dari 0,05 dengan nilai  $D = 0,0397$ . Analisis selanjutnya adalah menghitung kebaikan model berdasarkan RMSE *out-sample* yang ditampilkan pada Tabel 4.29.

**Tabel 4.29** Akurasi Peramalan Model ARIMAX Skenario 3


Replikasi	RMSE	
	<i>In-sample</i>	<i>Out-Sample</i>
1	3,02958	2,99761
2	3,15278	3,17965
3	3,27168	3,62905
4	3,10292	7,00407
5	2,96971	4,22784

Setelah memenuhi asumsi independen dan berdistribusi normal maka dilakukan pengujian varians residual homogen dengan uji *Lagrange Multiplier*. Apabila varians tidak homogen maka akan dilanjutkan pemodelan ARCH. Hasil pengujian *Lagrange Multiplier* ditampilkan pada Tabel 4.30 untuk replikasi ketiga, hasil tersebut menunjukkan bahwa varians residual tidak homogen karena  $p$ -value kurang dari 0,05. Sehingga bisa disimpulkan bahwa model ARIMAX dengan variasi kalender untuk Skenario 1 pada replikasi ketiga tidak memenuhi asumsi identik.

**Tabel 4.30** Uji Heteroskedastisitas Model ARIMAX Skenario 3

<i>k</i>	<i>Chi-Sq</i>	<i>p-value</i>
1	2,13267	0,144189
2	2,301208	0,316446
3	2,207377	0,530497
4	4,369152	0,358346
5	6,344247	0,274148
6	9,633202	0,140973
7	14,86923	0,037713
8	14,49432	0,069757
9	14,87994	0,094287
10	14,64027	0,145738
11	15,37775	0,165848
12	15,46738	0,216866

Tahap pertama yang dilakukan untuk pemodelan ARCH adalah menentukan orde ARCH . Penentuan orde berdasarkan lag yang signifikan atau lag yang tinggi dibandingkan lag-lag yang lainnya terhadap plot ACF dan PACF residual kuadrat. Plot ACF dan PACF residual kuadrat pada model ARIMAX ditampilkan pada Gambar 4.13.

**Gambar 4.13** Plot ACF dan PACF Residual Kuadrat Model ARIMAX Replikasi Tiga

Berdasarkan Gambar 4.13, model ARCH yang terbentuk adalah ARCH ([24]), sehingga model ARCH dapat ditulis sebagai berikut

$$\hat{\sigma}_t^2 = \hat{\theta}_0 + \hat{\theta}_{24} n_{t-24}^2$$

Selanjutnya adalah melakukan estimasi parameter pada persamaan tersebut. Hasil persamaan ditampilkan pada Tabel 4.31.


**Tabel 4.31** Hasil Estimasi Parameter ARCH([24]) Skenario 3

Parameter	Estimasi	Standard Error	t-value	p-value
$\theta_0$	5,7733	1,3289	4,34	<0,0001
$\theta_{24}$	0,5112	0,1852	2,76	0,0058

Setelah dilakukan estimasi parameter, maka persamaan ARCH([24]) menjadi  $\hat{\sigma}_t^2 = 5,7733 + 0,5112n_{t-24}^2$ . Meskipun residual tidak memenuhi asumsi homogen, model ARCH tersebut hanya akan berpengaruh pada terhadap penentuan batas atas dan batas bawah untuk ramalan interval. Batas atas dan bawah dapat diperoleh dari  $\hat{Z}_t \pm 1.96\sqrt{\hat{\sigma}_t^2}$  dengan  $\hat{\sigma}_t^2$  merupakan model ARCH.

### B. Neural Network Untuk Skenario 3

Pada pemodelan *Neural Network* input yang digunakan adalah lag-lag yang keluar pada PACF dari data simulasi untuk skenario 3 dan variabel *dummy*. Berikut PACF untuk lima replikasi ditampilkan pada Gambar 4.14.



**Gambar 4.14** Plot PACF Replikasi (a) satu, (b) dua, (c) tiga, (d) empat, dan (e) lima Skenario 3

Pada Gambar 4.14, lag yang signifikan pada plot PACF adalah lag 1, lag 11, lag 12, dan lag 13. Sehingga input yang digunakan adalah  $Z_{t-1}, Z_{t-3}, Z_{t-10}, Z_{t-11}, Z_{t-12}$  dan  $Z_{t-13}$ . Kemudian dilakukan pengujian hubungan antar variabel dengan uji Terasvirta diperoleh sebagai berikut pada Tabel 4.32.

**Tabel 4.32** Uji Terasvirta Skenario 3

Replikasi	<i>Chi-Sq</i>	DF	<i>p-value</i>
1	354,4492	77	0,0000
2	338,9196	77	0,0000
3	323,0339	77	0,0000
4	343,4981	77	0,0000
5	352,5824	77	0,0000

Berdasarkan Tabel 4.32, hasil uji non-linieritas menggunakan uji Terasvirta menunjukkan hubungan yang non-linier karena *p-value* kurang dari 0,05. Sehingga input yang digunakan adalah  $Z_{t-1}, Z_{t-3}, Z_{t-10}, Z_{t-11}, Z_{t-12}$  dan  $Z_{t-13}$ . Kemudian dilakukan kombinasi *hidden neuron* yaitu 1, 2, 3, 4, 5, 10, dan 15 *neuron*. Berikut akurasi peramalan menggunakan *Neural Network* pada Tabel 4.33.

**Tabel 4.33** Akurasi Peramalan Model *Neural Network* dengan Input Lag Skenario 3

<i>Hidden Neuron</i>	Replikasi 1		Replikasi 2		Replikasi 3	
	RMSE		RMSE		RMSE	
	<i>In-sample</i>	<i>Out-sample</i>	<i>In-sample</i>	<i>Out-sample</i>	<i>In-sample</i>	<i>Out-sample</i>
1	8,798	<b>15,760</b>	9,623	<b>15,994</b>	9,749	<b>14,595</b>
2	8,040	16,370	8,856	16,123	9,050	16,703
3	7,868	17,678	8,277	17,317	8,695	15,830
4	7,855	17,657	9,273	18,030	7,885	18,196
5	7,057	18,835	8,754	17,987	7,700	16,059
10	8,020	17,413	8,337	16,287	7,332	16,169
15	7,610	22,466	8,948	15,660	7,802	16,284

**Tabel 4.33** Akurasi Peramalan Model *Neural Network* dengan Input Lag Skenario 3 (lanjutan)

<i>Hidden Neuron</i>	Replikasi 4		Replikasi 5	
	RMSE		RMSE	
	<i>In-sample</i>	<i>Out-sample</i>	<i>In-sample</i>	<i>Out-sample</i>
1	9,347	19,352	9,081	<b>16,059</b>
2	7,406	<b>17,729</b>	7,794	16,603
3	7,949	19,665	8,164	18,459
4	7,495	19,534	7,301	17,497
5	7,711	20,537	8,526	18,682
10	8,146	20,203	8,063	16,411
15	7,992	19,182	7,755	19,580

Berdasarkan Tabel 4.33, nilai RMSE *out-sample* terkecil pada replikasi ke satu, dua, tiga, dan lima dengan jumlah *hidden* 1 *neuron* sedangkan pada replikasi ke empat dengan jumlah *hidden* 2 *neuron* merupakan model yang terbaik. Kemudian akurasi

peramalan menggunakan *Neural Network* dengan input lag dan variabel *dummy* ditampilkan pada Tabel 4.34.


**Tabel 4.34** Akurasi Peramalan Model *Neural Network* dengan Input Lag dan *Dummy* Skenario 3

<i>Hidden Neuron</i>	Replikasi 1		Replikasi 2		Replikasi 3	
	RMSE		RMSE		RMSE	
	<i>In-sample</i>	<i>Out-sample</i>	<i>In-sample</i>	<i>Out-sample</i>	<i>In-sample</i>	<i>Out-sample</i>
1	6,2740	<b>16,2072</b>	6,1296	<b>16,8815</b>	7,2439	16,8202
2	6,2991	18,6288	6,1439	18,1276	6,3432	17,8917
3	5,5345	17,2861	5,4845	17,2505	6,3513	<b>15,9167</b>
4	4,3764	16,9677	6,1797	19,4154	4,9732	18,6081
5	4,1910	17,8749	5,1787	18,3103	4,6566	17,5652
10	3,7735	20,9900	3,9092	17,8945	4,0159	18,7468
15	4,1319	26,3047	3,7157	18,3891	3,2093	17,7580

**Tabel 4.34** Akurasi Peramalan Model *Neural Network* dengan Input Lag dan *Dummy* Skenario 3 (lanjutan)

<i>Hidden Neuron</i>	Replikasi 4		Replikasi 5	
	RMSE		RMSE	
	<i>In-sample</i>	<i>Out-sample</i>	<i>In-sample</i>	<i>Out-sample</i>
1	6,4462	19,3548	7,0917	19,2803
2	5,8667	20,2336	6,1372	18,0748
3	3,7669	18,3295	5,4629	18,0073
4	4,9081	19,3842	4,6472	21,6233
5	4,3612	18,1607	5,0470	20,2702
10	3,8667	18,9050	3,6326	<b>16,0935</b>
15	4,0738	<b>17,9870</b>	3,7565	24,2535

Berdasarkan Tabel 4.34, nilai RMSE *out-sample* terkecil pada replikasi ke satu dan dua dengan *hidden 1 neuron*, kemudian pada replikasi ke tiga dengan *hidden 3 neuron*, pada replikasi ke tiga dengan *hidden 5 neuron*, lalu pada replikasi ke empat dengan *hidden 15 neuron*, serta replikasi ke lima dengan jumlah *hidden 10 neuron* merupakan model yang terbaik. Namun secara keseluruhan, jika dilihat dari RMSE *out-sample* pada *Neural Network* dengan input lag saja dan input lag & *dummy* lebih bagus menggunakan input lag saja karena memiliki nilai RMSE *out-sample* yang lebih kecil dibandingkan input lag & *dummy*. Sehingga pada skenario 3 menggunakan input lag saja sebagai model terbaik. Berikut arsitektur FFNN model terbaik setiap replikasi ditampilkan pada Gambar 4.15.



**Gambar 4.15** Arsitektur FFNN Model Terbaik (a) satu, (b) dua, (c) tiga, (d) empat, dan (e) lima Skenario 3

### C. Hybrid ARIMAX-NN Untuk Skenario 3

*Hybrid* ARIMAX-NN merupakan gabungan dari model linier yaitu ARIMAX dan model non-linier yaitu NN. Tahapan awal dalam melakukan *hybrid* ARIMAX-NN adalah mendapatkan model ARIMAX, kemudian residual dari ARIMAX akan dimodelkan dengan menggunakan model non linier yaitu *Neural Network*. Input yang digunakan dalam memodelkan *hybrid* ARIMAX-NN berdasarkan model AR pada ARIMAX yang didapatkan pada subab sebelumnya. Berdasarkan subab sebelumnya, model AR pada ARIMAX yang diperoleh adalah AR(1) pada replikasi 3, sehingga input yang digunakan pada *hybrid* ARIMAX-NN adalah  $Z_{t-1}$ . Kemudian dilakukan kombinasi *hidden*

*neuron* yaitu 1, 2, 3, 4, 5, 10, dan 15 *neuron*. Kemudian akan dihitung akurasi peramalan menggunakan *hybrid* ARIMAX-NN pada Tabel 4.35.

**Tabel 4.35** Akurasi Peramalan Model *Hybrid* ARIMAX-NN Skenario 3


<i>Hidden Neuron</i>	Replikasi 1		Replikasi 2		Replikasi 3	
	RMSE		RMSE		RMSE	
	<i>In-sample</i>	<i>Out-sample</i>	<i>In-sample</i>	<i>Out-sample</i>	<i>In-sample</i>	<i>Out-sample</i>
1	3,0308	<b>2,9756</b>	3,1608	<b>3,1795</b>	3,2596	3,6147
2	3,0305	2,9897	3,1577	3,1951	3,2571	3,6013
3	3,0303	2,9912	3,1574	3,1993	3,2611	3,6206
4	3,0305	2,9888	3,1576	3,2033	3,2605	3,6002
5	3,0302	2,9971	3,1572	3,2080	3,2593	<b>3,5839</b>
10	3,0298	3,0143	3,1565	3,2139	3,2589	3,6145
15	3,0294	2,9876	3,1573	3,2049	3,2543	3,6188

**Tabel 4.35** Akurasi Peramalan Model *Hybrid* ARIMAX-NN Skenario 3 (lanjutan)

<i>Hidden Neuron</i>	Replikasi 4		Replikasi 5	
	RMSE		RMSE	
	<i>In-sample</i>	<i>Out-sample</i>	<i>In-sample</i>	<i>Out-sample</i>
1	3,0900	<b>6,9872</b>	2,9727	4,2259
2	3,0837	7,0139	2,9697	<b>4,1973</b>
3	3,0809	7,0582	2,9700	4,2073
4	3,0776	7,0564	2,9696	4,1987
5	3,0791	7,0700	2,9696	4,2090
10	3,0785	7,1277	2,9696	4,2079
15	3,0720	7,0859	2,9649	4,2271

Berdasarkan Tabel 4.35, nilai RMSE *out-sample* terkecil pada replikasi ke satu, dua dan empat dengan *hidden 1 neuron*, kemudian pada replikasi ke tiga dengan *hidden 5 neuron*, dan pada replikasi ke lima dengan *hidden 2 neuron* merupakan model yang terbaik. Berikut arsitektur model terbaik pada setiap replikasi ditampilkan pada Gambar 4.16.





**Gambar 4.16** Arsitektur Model Terbaik Replikasi (a) satu, (b) dua, (c) tiga, (d) empat, dan (e) lima Skenario 3


Kemudian dilakukan pengujian varians residual homogen dengan uji *Lagrange Multiplier* pada Tabel 4.36.

**Tabel 4.36** Uji Heteroskedastisitas Model *Hybrid ARIMAX-NN* Skenario 3

<i>K</i>	<i>Chi-Sq</i>	<i>p-value</i>
1	2,443004	0,11805
2	2,83605	0,242192
3	2,731165	0,434957
4	4,71992	0,317261
5	6,95349	0,224122
6	10,59386	0,101769
7	16,00996	0,025026
8	16,524	0,035465
9	16,13136	0,064189
10	16,61202	0,083402
11	16,56889	0,12129
12	17,2733	0,139603

Apabila varians tidak homogen maka akan dilanjutkan pemodelan ARCH. Berdasarkan Tabel 4.36, hasil pengujian *Lagrange Multiplier* untuk replikasi ketiga, menunjukkan bahwa varians residual tidak homogen karena di lag 7 hingga lag 8 *p-value* kurang dari 0,05. Tahap pertama yang dilakukan untuk pemodelan ARCH adalah menentukan orde ARCH. Penentuan orde

berdasarkan lag yang signifikan atau lag yang tinggi dibandingkan lag-lag yang lainnya terhadap plot ACF dan PACF residual kuadrat. Plot ACF dan PACF residual kuadrat pada model *hybrid* ARIMAX-NN ditampilkan pada Gambar 4.17.



**Gambar 4.17** Plot ACF dan PACF Residual Kuadrat Model *Hybrid* ARIMAX-NN Replikasi Tiga

Berdasarkan Gambar 4.19, model ARCH yang terbentuk adalah ARCH ([24]), sehingga model ARCH dapat ditulis sebagai berikut

$$\hat{\sigma}_t^2 = \hat{\theta}_0 + \hat{\theta}_{24} n_{t-48}^2$$

Selanjutnya adalah melakukan estimasi parameter pada persamaan tersebut. Hasil persamaan ditampilkan pada Tabel 4.37.

**Tabel 4.37** Hasil Estimasi Parameter ARCH([24]) Skenario 3

Parameter	Estimasi	Standard Error	t-value	p-value
$\theta_0$	6,0876	1,1910	5,11	<0,0001
$\theta_{24}$	0,4606	0,1728	2,67	0,0077

Setelah dilakukan estimasi parameter, maka persamaan ARCH([24]) menjadi  $\hat{\sigma}_t^2 = 6,0876 + 0,4606n_{t-24}^2$ . Meskipun residual tidak memenuhi asumsi homogen, model ARCH tersebut hanya akan berpengaruh pada terhadap penentuan batas atas dan batas bawah untuk ramalan interval. Batas atas dan bawah dapat diperoleh dari  $\hat{Z}_t \pm 1.96\sqrt{\hat{\sigma}_t^2}$  dengan  $\hat{\sigma}_t^2$  merupakan model ARCH.

#### 4.1.4 Skenario 4

Pada skenario 4, membangkitkan data bulanan mulai dari Januari 2001 hingga Desember 2016 yang bersifat heterogen dan mengikuti proses *Exponential Smooth Transition Autoregressive*

(ESTAR-2). Diberikan persamaan untuk setiap masing-masing komponen kemudian dilakukan replikasi sebanyak lima kali. Replikasi dibedakan dengan membangkitkan  $a_t$  sebanyak lima kali. Berikut persamaan untuk setiap masing-masing komponen.

$$T_t = 0,3t$$


$$S_t = 8M_{1,t} + 10M_{2,t} + 14M_{3,t} + 23M_{4,t} + 25M_{5,t} + 28M_{6,t} + \\ 30M_{7,t} + 26M_{8,t} + 24M_{9,t} + 22M_{10,t} + 16M_{11,t} + 12M_{12,t}$$

dimana  $\beta \sim Uniform(a,b)$ . Penjelasan parameter untuk distribusi  $Uniform(a,b)$  disetiap bulannya pada Tabel 4.24.

$$CV_t = 40D_{1,t-1} + 30D_{2,t-2} + 25D_{3,t-3} + 20D_{4,t-4} + \\ 5D_{1,t} + 25D_{2,t} + 50D_{3,t} + 70D_{4,t}$$

$$N_t = 6,5N_{t-1} \exp(-0,25N_{t-1}^2) + a_t, \text{ dengan } a_t \sim N(0,1)$$

Kemudian dilakukan *time series plot* dan *box plot* untuk replikasi ketiga pada skenario 4.



**Gambar 4.18** (a) *Time Series Plot* Data Simulasi Replikasi Pertama, (b) *Scatter Plot* untuk Komponen Residual dengan Lag 1, (c) *Box Plot* Data Simulasi, dan (d) *Box Plot* Data Simulasi tanpa Tren Skenario 4

Berdasarkan Gambar 4.18 (a). tidak jauh berbeda dengan Gambar 4.11 (a) namun perbedaannya komponen residual pada lag 1 memiliki pola hubungan yang non-linier. Jika dilihat dari *box plot* pada Gambar 4.18 (c) dan (d) sebaran data tidak sama pada setiap bulannya sehingga terdapat varians yang cukup rendah serta varians yang cukup tinggi. Kemudian jika dilihat dari varians pada setiap bulannya. mengindikasikan bahwa data tersebut heterogen. Setelah itu, akan dianalisis menggunakan metode ARIMAX, *Neural Network*, dan *Hybrid ARIMAX-NN*.

#### A. ARIMAX Untuk Skenario 4

Tahap awal pembentukan model ARIMAX adalah mengacu pada pemodelan regresi *time series*. Berikut model *regresi time series* untuk data simulasi.

$$\begin{aligned} Z_t = & \delta t + \beta_1 M_{1,t} + \beta_2 M_{2,t} + \beta_3 M_{3,t} + \beta_4 M_{4,t} + \beta_5 M_{5,t} + \beta_6 M_{6,t} + \beta_7 M_{7,t} \\ & + \beta_8 M_{8,t} + \beta_9 M_{9,t} + \beta_{10} M_{10,t} + \beta_{11} M_{11,t} + \beta_{12} M_{12,t} + \gamma_1 D_{1,t} + \gamma_2 D_{2,t} \\ & + \gamma_3 D_{3,t} + \gamma_4 D_{4,t} + \alpha_1 D_{1,t-1} + \alpha_2 D_{2,t-1} + \alpha_3 D_{3,t-1} + \alpha_4 D_{4,t-1} + a_t \end{aligned}$$

Kemudian dilakukan estimasi parameter dari model regresi *time series*. Hasil estimasi parameter tersebut ditampilkan pada Tabel 4.38. Berdasarkan uji signifikansi parameter pada model variasi kalender diperoleh parameter yang sudah signifikan dikarenakan *p-value* kurang dari  $\alpha$  (0,05). Sehingga persamaan regresi *time series* untuk replikasi ke tiga sebagai berikut.

$$\begin{aligned} Z_t = & 0,30t + 9M_{1,t} + 6,78M_{2,t} + 11,56M_{3,t} + 11,78M_{4,t} + 17,61M_{5,t} \\ & + 19,00M_{6,t} + 21,36M_{7,t} + 18,05M_{8,t} + 17,94M_{9,t} + 19,75M_{10,t} \\ & + 9,76M_{11,t} + 9,88M_{12,t} + 14,515D_{1,t} + 28,4175D_{2,t} + 46,98D_{3,t} \\ & + 71,86D_{4,t} + 43,51D_{1,t-1} + 27,83D_{2,t-1} + 26,32D_{3,t-1} + 18,93D_{4,t-1} \\ & + a_t \end{aligned}$$

**Tabel 4.38** Estimasi Parameter Regresi *Time Series* Replikasi Tiga

Parameter	Estimasi	Standar Error	t-value	P-value
$\delta$	0,303	0,006	44,58	<0,0001
$\beta_1$	9,009	1,338	6,73	<0,0001
$\beta_2$	6,781	1,341	5,06	<0,0001
$\beta_3$	11,561	1,344	8,60	<0,0001
$\beta_4$	11,788	1,347	8,75	<0,0001
$\beta_5$	17,619	1,350	13,05	<0,0001
$\beta_6$	19,005	1,368	13,08	<0,0001
$\beta_7$	21,362	1,404	15,21	<0,0001
$\beta_8$	18,053	1,408	12,82	<0,0001
$\beta_9$	17,943	1,425	12,59	<0,0001
$\beta_{10}$	19,755	1,456	13,57	<0,0001
$\beta_{11}$	9,767	1,443	6,76	<0,0001
$\beta_{12}$	9,889	1,399	7,06	<0,0001
$\gamma_1$	14,515	2,819	5,15	<0,0001
$\gamma_2$	28,417	2,443	11,63	<0,0001
$\gamma_3$	46,982	2,436	19,29	<0,0001
$\gamma_4$	71,861	2,442	29,42	<0,0001
$\alpha_1$	43,515	2,827	15,39	<0,0001
$\alpha_2$	27,835	2,443	11,39	<0,0001
$\alpha_3$	26,321	2,435	10,81	<0,0001
$\alpha_4$	18,939	2,435	7,77	<0,0001

Persamaan pada model regresi *time series* untuk replikasi satu hingga replikasi lima menghasilkan residual yang belum *white noise* yang berarti residual mengandung autokorelasi karena *p-value* yang kurang dari 0,05 pada lag 6 hingga lag 36. Hal ini ditampilkan pada Tabel 4.39.


**Tabel 4.39** Uji Asumsi *White Noise* Residual Regresi *Time Series* Skenario 4

Hingga Lag ke-	Replikasi 1			Replikasi 2			Replikasi 3		
	Uji <i>White Noise</i>			Uji <i>White Noise</i>			Uji <i>White Noise</i>		
	$\chi^2$	Df	P-value	$\chi^2$	Df	P-value	$\chi^2$	df	P-value
6	20,52	6	0,0022	13,07	6	0,0409	16,66	6	0,0106
12	22,52	12	0,0321	17,16	12	0,1438	19,62	12	0,0745
18	30,8	18	0,0304	23,92	18	0,1577	24,03	18	0,1539
24	43,86	24	0,0079	30,66	24	0,1638	36,12	24	0,0535
30	49,32	30	0,0146	34,01	30	0,2806	42,86	30	0,0603
36	52,5	36	0,0372	35,62	36	0,4863	60,38	36	0,0066

**Tabel 4.39** Uji Asumsi *White Noise* Residual Regresi *Time Series* (lanjutan)

Hingga Lag ke-	Replikasi 4			Replikasi 5		
	Uji <i>White Noise</i>			Uji <i>White Noise</i>		
	$\chi^2$	df	<i>P-value</i>	$\chi^2$	df	<i>P-value</i>
6	16,25	6	0,0124	9,97	6	0,126
12	22,24	12	0,0349	14,45	12	0,2727
18	28,53	18	0,0544	23,22	18	0,1824
24	31,31	24	0,1449	38,12	24	0,0337
30	41,87	30	0,0734	45,41	30	0,0354
36	51,78	36	0,0429	50,73	36	0,0526

Kemudian tahap pertama yang dilakukan ketika residual belum *white noise* adalah pembentukan model ARIMA berdasarkan plot ACF dan PACF residual regresi *time series* guna mendapatkan model yang memenuhi asumsi independen yang ditampilkan pada Gambar 4.19.



**Gambar 4.19** Plot ACF dan PACF Residal Regresi *Time Series* Replikasi Tiga Berdasarkan Gambar 4.19, plot PACF *cut off* setelah lag 1 serta ACF membentuk pola *dies down* sehingga model ARIMA yang dapat dibentuk adalah model ARIMA (1,0,0). Hasil estimasi parameter untuk model ARIMA (1,0,0) ditampilkan pada Tabel 4.40 yang menunjukkan semua parameter signifikan karena *p-value* kurang dari 0,05 serta menghasilkan residual yang independen yang ditampilkan pada Tabel 4.41, karena tidak ada *p-value* yang kurang dari 0,05.

**Tabel 4.40** Estimasi Parameter dan Uji signifikansi Parameter ARIMA

Replikasi	Model	Parameter	Estimasi	<i>t-value</i>	<i>P-value</i>	Keterangan
1	ARIMA(1,0,0)	$\phi_1$	0,2851	3,99	<,0001	Signifikan
2	ARIMA(1,0,0)	$\phi_1$	0,2065	2,82	0,0053	Signifikan
3	ARIMA(1,0,0)	$\phi_1$	0,21742	2,97	0,0033	Signifikan
4	ARIMA(1,0,0)	$\phi_1$	0,27447	3,78	0,0002	Signifikan
5	ARIMA(1,0,0)	$\phi_1$	0,15571	2,10	0,0368	Signifikan

**Tabel 4.41** Uji Asumsi Independen Skenario 4

Hingga Lag ke-	Replikasi 1			Replikasi 2			Replikasi 3		
	Uji White Noise			Uji White Noise			Uji White Noise		
	$\chi^2$	Df	P-value	$\chi^2$	df	P-value	$\chi^2$	Df	P-value
6	4,12	5	0,5328	4,92	5	0,4258	3,98	5	0,5529
12	6,1	11	0,8633	10,63	11	0,475	7,33	11	0,7717
18	16,6	17	0,4817	20,76	17	0,2371	10,83	17	0,8653
24	24,08	23	0,3992	29,24	23	0,1724	18,09	23	0,7527
30	27,2	29	0,561	33,27	29	0,2671	23,41	29	0,7574
36	30,17	35	0,7005	35,13	35	0,4618	37,48	35	0,3559

**Tabel 4.41** Uji Asumsi Independen Skenario 4 (lanjutan)

Hingga Lag ke-	Replikasi 4			Replikasi 5		
	Uji <i>White Noise</i>			Uji <i>White Noise</i>		
	df	<i>P-value</i>		df	<i>P-value</i>	
6	0,83	5	0,9752	4,41	5	0,4921
12	6,75	11	0,8186	8,99	11	0,623
18	13,81	17	0,6808	14,85	17	0,6064
24	16,76	23	0,8208	26,13	23	0,2946
30	28,12	29	0,5115	32,53	29	0,2973
36	33,21	35	0,5545	37,41	35	0,359

Tahap selanjutnya adalah membentuk model ARIMAX yakni gabungan antara model ARIMA dan model regresi *time series* kemudian diestimasi secara simultan pada Lampiran 25 hingga 29.

a. Model ARIMAX untuk replikasi satu

$$\begin{aligned}
 Z_t = & 0,294t + 10,195M_{1,t} + 8,29M_{2,t} + 12,68M_{3,t} + 12,74M_{4,t} + 17,9M_{5,t} \\
 & + 17,279M_{6,t} + 20,3104M_{7,t} + 18,129M_{8,t} + 21,584M_{9,t} + 21,234M_{10,t} \\
 & + 10,964M_{11,t} + 9,440M_{12,t} + 14,175D_{1,t} + 25,470D_{2,t} + 50,093D_{3,t} \\
 & + 70,411D_{4,t} + 38,117D_{1,t-1} + 23,30D_{2,t-1} + 25,89D_{3,t-1} + 17,981D_{4,t-1} \\
 & + \frac{1}{(1-0,297B)} a_t
 \end{aligned}$$

b. Model ARIMAX untuk replikasi dua

$$\begin{aligned}
 Z_t = & 0,289t + 9,47M_{1,t} + 9,699M_{2,t} + 13,50M_{3,t} + 12,80M_{4,t} + 18,65M_{5,t} \\
 & + 18,616M_{6,t} + 23,547M_{7,t} + 20,419M_{8,t} + 20,774M_{9,t} + 23,040M_{10,t} \\
 & + 13,142M_{11,t} + 10,342M_{12,t} + 12,177D_{1,t} + 24,953D_{2,t} + 46,356D_{3,t} \\
 & + 68,11D_{4,t} + 41,958D_{1,t-1} + 26,769D_{2,t-1} + 21,795D_{3,t-1} + 15,976D_{4,t-1} \\
 & + \frac{1}{(1-0,219B)} a_t
 \end{aligned}$$

## c. Model ARIMAX untuk replikasi tiga

$$\begin{aligned}
Z_t = & 0.304t + 8.979M_{1,t} + 6.71M_{2,t} + 11.479M_{3,t} + 11.703M_{4,t} + 17.53M_{5,t} \\
& + 18.959M_{6,t} + 21.409M_{7,t} + 18.123M_{8,t} + 17.805M_{9,t} + 19.579M_{10,t} \\
& + 9.642M_{11,t} + 9.707M_{12,t} + 15.864D_{1,t} + 28.283D_{2,t} + 46.824D_{3,t} \\
& + 70.902D_{4,t} + 44.574D_{1,t-1} + 27.55D_{2,t-1} + 25.463D_{3,t-1} + 19.167D_{4,t-1} \\
& + \frac{1}{(1 - 0.234B)} a_t
\end{aligned}$$

## d. Model ARIMAX untuk replikasi empat

$$\begin{aligned}
Z_t = & 0.304t + 7.190M_{1,t} + 7.18M_{2,t} + 11.65M_{3,t} + 10.86M_{4,t} + 16.22M_{5,t} \\
& + 17.44M_{6,t} + 20.155M_{7,t} + 19.944M_{8,t} + 19.402M_{9,t} + 21.58M_{10,t} \\
& + 10.87M_{11,t} + 7.84M_{12,t} + 10.35D_{1,t} + 25.23D_{2,t} + 47.31D_{3,t} \\
& + 68.09D_{4,t} + 41.72D_{1,t-1} + 26.76D_{2,t-1} + 21.93D_{3,t-1} + 15.93D_{4,t-1} \\
& + \frac{1}{(1 - 0.307B)} a_t
\end{aligned}$$

## e. Model ARIMAX untuk replikasi lima

$$\begin{aligned}
Z_t = & 0.304t + 8.806M_{1,t} + 7.753M_{2,t} + 10.66M_{3,t} + 12.51M_{4,t} + 18.18M_{5,t} \\
& + 17.021M_{6,t} + 20.481M_{7,t} + 18.831M_{8,t} + 20.909M_{9,t} + 20.478M_{10,t} \\
& + 11.219M_{11,t} + 8.057M_{12,t} + 14.957D_{1,t} + 21.990D_{2,t} + 47.584D_{3,t} \\
& + 72.54D_{4,t} + 39.857D_{1,t-1} + 24.139D_{2,t-1} + 26.223D_{3,t-1} + 16.968D_{4,t-1} \\
& + \frac{1}{(1 - 0.163B)} a_t
\end{aligned}$$

Selanjutnya dilakukan Uji Kolmogorov-Smirnov pada persamaan model ARIMAX dengan replikasi tiga. Hasil pengujian ini menyimpulkan bahwa residual sudah berdistribusi normal karena *p-value* lebih dari 0,05 dengan nilai  $D = 0,0480$ . Analisis selanjutnya adalah menghitung kebaikan model berdasarkan RMSE *out-sample* yang ditampilkan pada Tabel 4.42.

Tabel 4.42 Akurasi Peramalan Model ARIMAX Skenario 4

Replikasi	RMSE	
	<i>In-sample</i>	<i>Out-Sample</i>
1	3,65431	5,35561
2	3,82171	2,0675
3	4,2805	5,42831
4	3,83032	5,18395
5	3,70137	5,21285




Setelah memenuhi asumsi independen dan berdistribusi normal maka dilakukan pengujian varians residual homogen dengan uji *Lagrange Multiplier*. Apabila varians tidak homogen maka akan dilanjutkan pemodelan ARCH. Hasil pengujian *Lagrange Multiplier* ditampilkan pada Tabel 4.43 untuk replikasi ketiga, hasil tersebut menunjukkan bahwa varians residual tidak homogen karena *p-value* kurang dari 0,05 .

**Tabel 4.43** Uji Heteroskedastisitas Model ARIMAX Skenario 4

<i>k</i>	<i>Chi-Sq</i>	<i>p-value</i>
1	4,302382	0,038059
2	6,445519	0,039845
3	6,460651	0,091227
4	8,796061	0,066404
5	9,56514	0,088537
6	11,69553	0,069116
7	11,83444	0,106137
8	12,46455	0,131649
9	13,34685	0,14753
10	12,97623	0,225004
11	13,05109	0,289999
12	13,56665	0,329232

Tahap pertama yang dilakukan untuk pemodelan ARCH adalah menentukan orde ARCH. Penentuan orde berdasarkan lag yang signifikan atau lag yang tinggi dibandingkan lag-lag yang lainnya terhadap plot ACF dan PACF residual kuadrat. Plot ACF dan PACF residual kuadrat pada model ARIMAX ditampilkan pada Gambar 4.20.



**Gambar 4.20** Plot ACF dan PACF Residual Kuadrat Model ARIMAX Replikasi Tiga

Berdasarkan Gambar 4.20, model ARCH yang terbentuk adalah ARCH ([1,24,36]), ARCH ([1,36]), ARCH ([24,36]), ARCH ([1]), ARCH ([24]) atau ARCH ([36]). Kemudian, melakukan estimasi parameter yang ditampilkan pada Tabel 4.44

**Tabel 4.44** Hasil Estimasi Parameter ARCH Skenario 4


Model	Parameter	Estimasi	Standard Error	t-value	p-value
ARCH ([1,24,36])	$\theta_0$	13,229	3,038	4,35	<0,0001
	$\theta_1$	$-1,32 \cdot 10^{-23}$	$1,51 \cdot 10^{-13}$	0,00	1,000
	$\theta_{24}$	0,223	0,158	1,42	0,1569
	$\theta_{36}$	0,053	0,099	0,53	0,5938
ARCH ([1,36])	$\theta_0$	16,374	2,683	6,10	<0,0001
	$\theta_1$	0,000	$2,51 \cdot 10^{-15}$	0,00	1,000
	$\theta_{36}$	0,102	0,129	0,79	0,4308
ARCH ([24,36])	$\theta_0$	13,228	3,038	4,35	<0,0001
	$\theta_{24}$	0,223	0,158	1,42	0,1568
	$\theta_{36}$	0,053	0,099	0,53	0,5938
ARCH ([1])	$\theta_0$	18,322	1,881	9,74	<0,0001
	$\theta_1$	$4,52 \cdot 10^{-23}$	$5,66 \cdot 10^{-15}$	0,00	1,000
ARCH ([24])	$\theta_0$	13,804	2,966	4,65	<0,0001
	$\theta_{24}$	0,254	0,161	1,58	0,1142
ARCH ([36])	$\theta_0$	16,374	2,683	6,10	<0,0001
	$\theta_{36}$	0,102	0,129	0,79	0,430

Berdasarkan Tabel 4.44, menunjukkan hasil parameter ARCH yang tidak signifikan, karena *p-value* pada model ARCH([1,24,36]), ARCH([1,36]), ARCH([24,36]), ARCH([1]), ARCH([24]) atau ARCH([36]) lebih dari 0,05 sehingga tidak mempunyai efek ARCH atau dalam kata lain residual dari model ARIMAX pada replikasi tiga bersifat homogen. Jadi bisa disimpulkan bahwa untuk replikasi tiga sudah memenuhi asumsi IIDN (identik, independen, dan berdistribusi normal).

## B. Neural Network Untuk Skenario 4

Pada pemodelan *Neural Network* input yang digunakan adalah lag-lag yang keluar pada PACF dari data simulasi untuk skenario

4 dan variabel *dummy*. Berikut PACF untuk lima replikasi ditampilkan pada Gambar 4.21.



**Gambar 4.21** Plot PACF Replikasi (a) satu, (b) dua, (c) tiga, (d) empat, dan (e) lima Skenario 4

Pada Gambar 4.21, lag yang signifikan pada plot PACF untuk replikasi satu adalah lag 1, lag 3, lag 10, lag 11, lag 12, dan lag 13. Sehingga input yang digunakan pada replikasi satu adalah  $Z_{t-1}, Z_{t-3}, Z_{t-10}, Z_{t-11}, Z_{t-12}$  dan  $Z_{t-13}$ . Kemudian dilakukan pengujian hubungan antar variabel dengan uji Terasvirta pada Tabel 4.45.

**Tabel 4.45** Uji Terasvirta Skenario 4

Replikasi	<i>Chi-Sq</i>	DF	<i>p-value</i>
1	314,596	77	0.0000
2	323,7731	77	0.0000
3	199,7457	50	0.0000
4	281,221	50	0.0000
5	266,8518	77	0.0000

Berdasarkan Tabel 4.45, hasil uji non-linieritas menggunakan uji Terasvirta menunjukkan hubungan yang non-linier karena *p-value* kurang dari 0,05. Sehingga input yang digunakan adalah  $Z_{t-1}, Z_{t-3}, Z_{t-10}, Z_{t-11}, Z_{t-12}$  dan  $Z_{t-13}$ . Kemudian dilakukan kombinasi *hidden neuron* yaitu 1, 2, 3, 4, 5, 10, dan 15 *neuron*. Berikut akurasi peramalan menggunakan *Neural Network* pada Tabel 4.46.

**Tabel 4.46** Akurasi Peramalan Model *Neural Network* dengan Input Lag Skenario 4

<i>Hidden Neuron</i>	Replikasi 1		Replikasi 2		Replikasi 3	
	RMSE		RMSE		RMSE	
	<i>In-sample</i>	<i>Out-sample</i>	<i>In-sample</i>	<i>Out-sample</i>	<i>In-sample</i>	<i>Out-sample</i>
1	9,916	<b>16,210</b>	9,285	20,621	9,750	<b>18,771</b>
2	9,068	16,649	8,017	<b>18,623</b>	8,882	20,670
3	8,490	17,856	9,987	25,807	9,110	21,064
4	8,427	18,749	8,516	20,356	9,097	21,866
5	8,185	18,797	8,289	22,764	9,264	22,760
10	8,916	17,601	8,310	20,405	8,628	22,435
15	9,229	19,465	8,948	15,660	8,876	22,119

**Tabel 4.46** Akurasi Peramalan Model *Neural Network* dengan Input Lag Skenario 4 (lanjutan)

<i>Hidden Neuron</i>	Replikasi 4		Replikasi 5	
	RMSE		RMSE	
	<i>In-sample</i>	<i>Out-sample</i>	<i>In-sample</i>	<i>Out-sample</i>
1	9,805	<b>16,870</b>	10,003	<b>16,164</b>
2	8,837	17,378	9,334	18,128
3	7,882	18,588	9,804	16,968
4	8,675	19,449	9,358	18,243
5	8,515	18,184	9,587	18,050
10	7,769	17,554	9,250	17,345
15	8,314	19,385	9,361	19,806

Berdasarkan Tabel 4.46, nilai RMSE *out-sample* terkecil pada replikasi ke satu, tiga, empat dan lima dengan jumlah *hidden* 1 *neuron* sedangkan pada replikasi ke dua dengan jumlah *hidden* 2 *neuron* merupakan model yang terbaik. Kemudian akurasi peramalan menggunakan *Neural Network* dengan input lag dan variabel *dummy* ditampilkan pada Tabel 4.47.


**Tabel 4.47** Akurasi Peramalan Model *Neural Network* dengan Input Lag dan *Dummy* Skenario 4

<i>Hidden Neuron</i>	Replikasi 1		Replikasi 2		Replikasi 3	
	RMSE		RMSE		RMSE	
	<i>In-sample</i>	<i>Out-sample</i>	<i>In-sample</i>	<i>Out-sample</i>	<i>In-sample</i>	<i>Out-sample</i>
1	6,595	<b>17,293</b>	6,819	21,138	6,860	<b>20,412</b>
2	6,246	17,510	6,690	<b>19,728</b>	6,633	21,709
3	5,376	17,519	6,072	22,187	6,612	20,426
4	5,168	18,337	5,769	26,390	6,215	20,477
5	4,650	17,945	5,184	21,776	7,090	20,495
10	4,724	20,575	4,387	20,900	5,143	23,297
15	4,085	28,986	4,200	21,160	4,484	21,397

**Tabel 4.47** Akurasi Peramalan Model *Neural Network* dengan Input Lag dan *Dummy* Skenario 4 (lanjutan)

Hidden Neuron	Replikasi 4		Replikasi 5	
	RMSE		RMSE	
	In-sample	Out-sample	In-sample	Out-sample
1	6,902	<b>18,359</b>	6,828	18,497
2	5,387	21,097	6,615	18,749
3	6,320	19,002	5,589	18,614
4	6,538	19,924	4,407	19,800
5	5,382	20,566	5,926	21,340
10	5,038	19,069	4,173	<b>16,444</b>
15	4,423	20,225	4,056	20,040

Berdasarkan Tabel 4.47, nilai RMSE *out-sample* terkecil pada replikasi ke satu, tiga, dan empat dengan jumlah *hidden* 1 *neuron*, kemudian pada replikasi ke dua dengan jumlah *hidden* 2 *neuron*, serta pada replikasi ke lima dengan jumlah *hidden* 10 *neuron* merupakan model yang terbaik. Namun secara keseluruhan, jika dilihat dari RMSE *out-sample* pada *Neural Network* dengan input lag saja dan input lag & *dummy* lebih bagus menggunakan input lag saja karena memiliki nilai RMSE *out-sample* yang lebih kecil dibandingkan input lag & *dummy*. Sehingga pada skenario 4 menggunakan input lag saja sebagai model terbaik. Berikut arsitektur FFNN model terbaik setiap replikasi ditampilkan pada Gambar 4.22.



**Gambar 4.22** Arsitektur FFNN Model Terbaik (a) satu, (b) dua, (c) tiga, (d) empat, dan (e) lima Skenario 4

### C. Hybrid ARIMAX-NN Untuk Skenario 4

*Hybrid* ARIMAX-NN merupakan gabungan dari model linier yaitu ARIMAX dan model non-linier yaitu NN. Tahapan awal dalam melakukan *hybrid* ARIMAX-NN adalah mendapatkan model ARIMAX, kemudian residual dari ARIMAX akan dimodelkan dengan menggunakan model non linier yaitu *Neural Network*. Input yang digunakan dalam memodelkan *hybrid* ARIMAX-NN berdasarkan model AR pada ARIMAX yang diperoleh pada subab sebelumnya. Berdasarkan subab sebelumnya, model AR pada ARIMAX yang diperoleh adalah AR(1) pada replikasi 3, sehingga input yang digunakan pada *hybrid* ARIMAX-NN adalah  $Z_{t-1}$ . Kemudian dilakukan kombinasi *hidden neuron* yaitu 1, 2, 3, 4, 5, 10, dan 15 *neuron*. Kemudian akan dihitung akurasi peramalan menggunakan *hybrid* ARIMAX-NN pada Tabel 4.48.

**Tabel 4.48** Akurasi Peramalan Model *Hybrid* ARIMAX-NN Skenario 4


Hidden Neuron	Replikasi 1		Replikasi 2		Replikasi 3	
	RMSE		RMSE		RMSE	
	In-sample	Out-sample	In-sample	Out-sample	In-sample	Out-sample
1	3,6487	<b>5,3403</b>	3,8322	2,0673	4,2920	5,4262
2	3,6329	5,4731	3,7346	<b>1,9872</b>	4,2899	5,4387
3	3,6356	5,4301	3,8169	2,0660	4,2883	5,4258
4	3,6344	5,5080	3,8246	2,0672	4,2886	<b>5,4246</b>
5	3,6408	5,4151	3,8273	2,0646	4,2856	5,4438
10	3,6195	5,4585	3,8226	2,0640	4,2831	5,4371
15	3,5968	5,4671	3,8037	2,0605	4,2852	5,4481

**Tabel 4.48** Akurasi Peramalan Model *Hybrid* ARIMAX-NN Skenario 4  
(lanjutan)

Hidden Neuron	Replikasi 4		Replikasi 5	
	RMSE		RMSE	
	In-sample	Out-sample	In-sample	Out-sample
1	3,8393	<b>5,1811</b>	3,7060	5,2127
2	3,8353	5,2199	3,7028	5,2117
3	3,8355	5,2128	3,7057	5,2130
4	3,8348	5,2142	3,6976	5,2079
5	3,8348	5,2068	3,6964	<b>5,2030</b>
10	3,8354	5,2128	3,6943	5,2051
15	3,8335	5,2060	3,6939	5,2057

Berdasarkan Tabel 4.48, nilai RMSE *out-sample* terkecil pada replikasi ke satu dan empat dengan jumlah *hidden* 1 *neuron*,

kemudian pada replikasi ke dua dengan jumlah *hidden 2 neuron*, pada replikasi ke tiga dengan jumlah *hidden 4 neuron*, serta pada replikasi lima dengan jumlah *hidden 5 neuron* merupakan model yang terbaik. Berikut arsitektur model terbaik pada setiap replikasi ditampilkan pada Gambar 4.23.



**Gambar 4.23** Arsitektur Model Terbaik Replikasi (a) satu, (b) dua, (c) tiga, (d) empat, dan (e) lima Skenario 4


Kemudian dilakukan pengujian varians residual homogen dengan uji *Lagrange Multiplier* pada Tabel 4.49.

**Tabel 4.49** Uji Heteroskedastisitas Model *Hybrid* ARIMAX-NN Skenario 4

<i>k</i>	<i>Chi-Sq</i>	<i>p-value</i>
1	4,529195	0,033321
2	6,617364	0,036564
3	6,673388	0,08307
4	9,160411	0,057213
5	9,55905	0,088738
6	11,8262	0,06596
7	12,12888	0,096399
8	13,06184	0,10974
9	12,77268	0,173165
10	13,16215	0,214747
11	13,64782	0,253097
12	13,77612	0,315233

Apabila varians tidak homogen maka akan dilanjutkan pemodelan ARCH. Berdasarkan Tabel 4.49, hasil pengujian *Lagrange Multiplier* untuk replikasi ketiga, menunjukkan bahwa varians residual tidak homogen karena di lag 1 hingga 12 memiliki *p-value* kurang dari 0,05, namun pada lag 3 sampai lag 12 *p-value* lebih dari 0,05 dan semakin besar hingga lag 12 sehingga ada indikasi bahwa residual tersebut homogen.

Tahap pertama yang dilakukan untuk pemodelan ARCH adalah menentukan orde ARCH. Penentuan orde berdasarkan lag yang signifikan terhadap plot ACF dan PACF residual kuadrat. Plot ACF dan PACF residual kuadrat pada model *hybrid* ARIMAX-NN ditampilkan pada Gambar 4.24.



**Gambar 4.24** Plot ACF dan PACF Residual Kuadrat Model *Hybrid* ARIMAX-NN Replikasi Tiga

Berdasarkan Gambar 4.24, model ARCH yang terbentuk adalah ARCH([1,24,36]), ARCH([1,36]), ARCH([24,36]), ARCH([1]), ARCH([24]) atau ARCH([36]). Kemudian, melakukan estimasi parameter yang ditampilkan pada Tabel 4.50. Berdasarkan Tabel 4.52, menunjukkan hasil parameter ARCH yang tidak signifikan, karena *p-value* pada model ARCH ([1,24,36]), ARCH ([1,36]), ARCH ([24,36]), ARCH ([1]), ARCH ([24]) atau ARCH ([36]) lebih dari 0,05 sehingga tidak mempunyai efek ARCH atau dalam kata lain residual dari model *hybrid* ARIMAX-NN pada replikasi tiga bersifat homogen.



**Tabel 4.50** Hasil Estimasi Parameter ARCH Skenario 4

Model	Parameter	Estimasi	Standard Error	t-value	p-value
ARCH ([1,24,36])	$\theta_0$	13,055	3,013	4,33	<0,0001
	$\theta_1$	-5,88 10 <sup>-23</sup>	2,65 10 <sup>-14</sup>	0,00	1,000
	$\theta_{24}$	0,243	0,159	1,52	0,1274
	$\theta_{36}$	0,047	0,091	0,52	0,6040
ARCH ([1,36])	$\theta_0$	16,547	2,679	6,17	<0,0001
	$\theta_1$	0,000	7,55 10 <sup>-15</sup>	0,00	1,000
	$\theta_{36}$	0,095	0,125	0,77	0,4428
ARCH ([24,36])	$\theta_0$	13,056	3,013	4,33	<0,0001
	$\theta_{24}$	0,243	0,159	1,52	0,1274
	$\theta_{36}$	0,047	0,091	0,52	0,6040
ARCH ([1])	$\theta_0$	18,391	1,892	9,72	<0,0001
	$\theta_1$	-4,18 10 <sup>-15</sup>	9,451 10 <sup>-15</sup>	0,00	1,000
ARCH ([24])	$\theta_0$	13,568	2,943	4,61	<0,0001
	$\theta_{24}$	0,272	0,272	1,67	0,0946
ARCH ([36])	$\theta_0$	16,547	2,680	6,17	<0,0001
	$\theta_{36}$	0,095	0,125	0,77	0,4428

#### 4.1.5 Perbandingan Akurasi Peramalan


Setelah dilakukan analisis menggunakan metode ARIMAX, *Neural Network*, dan *Hybrid* ARIMAX-NN maka langkah selanjutnya adalah pemilihan metode terbaik dalam menganalisis skenario 1, 2, 3, dan 4. Kriteria kebaikan model terbaik berdasarkan nilai RMSE *out-sample*.

Nilai RMSE dari masing-masing metode ditampilkan pada Tabel 4.53. Berdasarkan Tabel 4.51, tampak bahwa hasil terbaik dalam melakukan peramalan menggunakan metode *Hybrid* ARIMAX-NN, karena menghasilkan nilai RMSE terkecil bila dibandingkan metode lainnya. Sehingga dapat disimpulkan bahwa untuk metode yang terbaik pada skenario 1, 2, 3, dan 4 adalah menggunakan *Hybrid* ARIMAX-NN. Hal itu sudah


sejalan dengan hasil *The M3-Competition* bahwa menggunakan kombinasi dari metode individu yang menggabungkan beberapa model peramalan akan meningkatkan akurasi ramalan.

**Tabel 4.51** Perbandingan Akurasi Peramalan


Skenario	Metode	Replikasi									
		1		2		3		4		5	
		RMSE		RMSE		RMSE		RMSE		RMSE	
		<i>In-sample</i>	<i>Out-sample</i>	<i>In-sample</i>	<i>Out-sample</i>	<i>In-sample</i>	<i>Out-sample</i>	<i>In-sample</i>	<i>Out-sample</i>	<i>In-sample</i>	<i>Out-sample</i>
1	ARIMAX	1,3284	1,49711	1,3665	2,1830	1,2499	2,2273	1,3949	2,0697	1,4963	2,8946
	NN	7,3990	18,2076	8,5847	17,4845	7,6252	18,5346	7,4073	17,4976	8,4033	21,1299
	Hybrid ARIMAX-NN	1,3176	<b>1,4889</b>	3,1410	<b>1,9243</b>	1,2516	<b>2,2212</b>	1,3945	<b>2,0531</b>	1,4967	<b>2,8812</b>
2	ARIMAX	2,9784	4,1382	2,8092	4,7754	2,9312	2,7107	3,0851	3,4334	3,1150	3,5837
	NN	9,4704	15,4424	9,7079	19,0796	8,8774	18,5136	9,5338	16,4049	9,1110	19,9389
	Hybrid ARIMAX-NN	2,9755	<b>4,1203</b>	2,9593	<b>4,7129</b>	2,8589	<b>2,6665</b>	2,9250	<b>3,3927</b>	3,1209	<b>3,5799</b>
3	ARIMAX	3,0296	2,9976	3,1528	3,1797	3,2717	3,6291	3,1029	7,0041	2,9697	4,2278
	NN	8,7981	15,7595	9,6225	15,9941	9,7486	14,5951	7,4055	17,7291	9,1110	19,9389
	Hybrid ARIMAX-NN	3,0308	<b>2,9756</b>	3,1608	<b>3,1795</b>	3,2593	<b>3,5839</b>	3,0900	<b>6,9872</b>	2,9697	<b>4,1973</b>
4	ARIMAX	3,6543	5,3556	3,8217	2,0675	4,2805	5,4283	3,8303	5,1840	3,7014	5,2129
	NN	9,9157	16,2100	8,0171	18,6234	9,7495	18,7714	9,8048	16,8705	10,0030	16,1638
	Hybrid ARIMAX-NN	3,6487	<b>5,3403</b>	3,7346	<b>1,9872</b>	4,2886	<b>5,4246</b>	3,8393	<b>5,1811</b>	3,6964	<b>5,2030</b>




**Gambar 4.25** Data Aktual Versus Forecast Studi Simulasi Homogen Linier Metode (a) ARIMAX, (b) NN, dan (c) Hybrid ARIMAX-NN



**Gambar 4.26** Data Aktual Versus Forecast Studi Simulasi Homogen Non-Linier Metode (a) ARIMAX, (b) NN, dan (c) Hybrid ARIMAX-NN




**Gambar 4.27** Data Actual Versus Forecast Studi Simulasi Heterogen Linier Metode (a) ARIMAX, (b) NN, dan (c) Hybrid ARIMAX-NN



**Gambar 4.28** Data Actual Versus Forecast Studi Simulasi Heterogen Non-Linier Metode (a) ARIMAX, (b) NN, dan (c) Hybrid ARIMAX-NN

## 4.2 Karakteristik *Inflow* dan *Outflow* Uang Kartal di Provinsi Jawa Barat

Analisis deskriptif dilakukan untuk menjelaskan mengenai gambaran umum dari data *inflow* dan *outflow* mulai bulan Januari 2004 hingga Desember 2016. Data bulan Januari 2004 hingga Desember 2015 digunakan sebagai data *in-sample* dan data Januari 2016 hingga Desember 2016 digunakan sebagai data *out-sample*. Pada analisis deskriptif ini, pola yang terbentuk dari data *inflow* dan *outflow* di Kantor Perwakilan Bank Indonesia Provinsi Jawa Barat ditampilkan menggunakan plot *time series* pada Gambar 4.29.



**Gambar 4.29** Plot *Time Series* (a) *Inflow* dan (b) *Outflow* Uang Kartal di Kantor Perwakilan Bank Indonesia Provinsi Jawa Barat

Berdasarkan Gambar 4.29 (a) dan (b) menunjukkan pola data *inflow* dan *outflow* mengalami perubahan tren. Tren pada tahun 2003 hingga 2006 cenderung meningkat, kemudian di tahun 2007 hingga 2010 mengalami penurunan yang cukup besar. Hal itu dikarenakan adanya kebijakan baru dalam rangka meningkatkan efektifitas dan efisiensi manajemen perbankan serta pengolahan uang oleh perbankan sehingga uang yang beredar di masyarakat meningkat kualitasnya. Kebijakan ini berlaku secara nasional pada Desember 2006 di seluruh wilayah Kantor Perwakilan Bank Indonesia. Hal itu berdampak pada penurunan terhadap mekanisme penyetoran dan penarikan uang rupiah oleh Bank Umum di Bank Indonesia. Kemudian pada tahun 2011 hingga 2016 mengalami tren yang meningkat. Hal itu disebabkan dampak dari kebijakan pada Desember 2006 serta adanya kebijakan baru yang dikeluarkan

oleh Bank Indonesia yaitu tentang mata uang dengan tujuan untuk menegaskan Rupiah sebagai mata uang Republik Indonesia beserta seluruh informasi fisik, penggunaan, serta sanksi terhadap penyelewengan, penyalahgunaan Rupiah dalam transaksi bisnis dan pembayaran di Republik Indonesia. Sehingga Bank Indonesia dalam periode 2003 hingga 2016 mengeluarkan tiga kali kebijakan baru dalam memenuhi uang kartal. Untuk lebih jelasnya dapat dilihat pada Tabel 4.52.

**Tabel 4.52** Kebijakan Bank Indonesia

Periode	Kebijakan
2003-2006	PBI No. 6/14/PBI/2004
2007- 2010	PBI No 9/10/PBI/2007
2011- 2016	UU No. 7 Tahun 2011


Kemudian, untuk mengetahui karakteristik data selain menggunakan *time series plot* bisa menggunakan statistika deskriptif. Statistika deskriptif dari data *inflow* dan *outflow* uang kartal dapat ditunjukkan pada Tabel 4.53.

**Tabel 4.53** Statistika Deskriptif *Inflow* dan *Outflow* Uang Kartal (Triliun)

Variabel	N	Mean	St. Dev	Maks,	Min,	Range
<i>Inflow</i>	156	4,027	2,497	14,735	0,618	14,117
<i>Outflow</i>	156	2,108	1,979	14,051	0,038	14,013

Berdasarkan informasi pada Tabel 4.53, rata-rata peredaran uang kartal di Kantor Perwakilan Bank Indonesia Provinsi Jawa Barat periode Januari 2004 hingga Desember 2016 untuk *inflow* mencapai 4,027 dengan standar deviasi sebesar 2,497. *Inflow* tertinggi sebesar 14,735 pada bulan Juli 2016. dimana pada bulan tersebut merupakan adanya hari raya Idul Fitri yang jatuh pada minggu pertama, sedangkan *inflow* terendah sebesar 0,618 pada bulan Juni 2007, sehingga *range* yang dihasilkan adalah 14,117. Kemudian untuk *outflow*, rata-rata peredaran uang kartal di Kantor Perwakilan Bank Indonesia Provinsi Jawa Barat periode Januari 2004 hingga Desember 2016 mencapai 2,108 dengan standar deviasi sebesar 1,979. *Outflow* tertinggi sebesar 14,051 jatuh pada bulan Juni 2016, dimana pada bulan tersebut merupakan satu bulan

sebelum hari raya Idul Fitri, sedangkan *outflow* terendah sebesar 0,038 pada bulan Januari 2009, sehingga *range* yang dihasilkan adalah 14,013. Selain itu, dapat pula disimpulkan bahwa variasi *inflow* lebih tinggi dibandingkan dengan *outflow*. Hal tersebut dilihat pada nilai standar deviasi dan range *inflow* lebih besar dibandingkan nilai *outflow*. Selanjutnya, untuk melihat pergerakan rata-rata peredaran uang kartal di Kantor Perwakilan Bank Indonesia Provinsi Jawa Barat periode Januari 2004 hingga Desember 2016 di setiap bulannya dapat menggunakan diagram batang yang ditampilkan pada Gambar 4.30.




**Gambar 4.30** Diagram Batang Rata-Rata Bulanan *Inflow* dan *Outflow* (Triliun) Uang Kartal di Kantor Perwakilan Bank Indonesia Provinsi Jawa Barat

Berdasarkan Gambar 4.30, menunjukkan bahwa rata-rata bulanan tertinggi untuk *inflow* di Kantor Perwakilan Bank Indonesia Provinsi Jawa Barat terjadi pada bulan Januari, Juli, Agustus, September, Oktober, dan November. Pada bulan Januari mempunyai nilai rata-rata *inflow* yang tinggi dikarenakan bulan tersebut merupakan bulan setelah perayaan natal dan tahun baru. sehingga masyarakat cenderung untuk menyetorkan uang ke bank. Untuk bulan Juli, Agustus, September, Oktober, dan November merupakan bulan yang berkaitan dengan terjadinya hari raya Idul Fitri. Kemudian untuk *outflow*, rata-rata bulanan tertinggi terjadi pada bulan Juni, Juli, dan Desember. Sama halnya dengan



pergerakan rata-rata *inflow*, pada bulan Juni dan Juli merupakan bulan yang berkaitan dengan terjadinya hari raya Idul Fitri. Sedangkan pada bulan Desember merupakan bulan perayaan Natal dan tahun baru, sehingga masyarakat cenderung untuk mengambil atau menarik uang dari Bank.

Berdasarkan diagram batang pada Gambar 4.30 menunjukkan adanya pengaruh yang signifikan hari raya Idul Fitri terhadap pergerakan *inflow* dan *outflow* uang kartal. Pada penelitian sebelumnya sudah dijelaskan bahwa pengaruh hari raya Idul Fitri berkaitan dengan minggu terjadinya hari raya Idul Fitri. Hal tersebut dibuktikan pada diagram batang pada Gambar 4.31.



**Gambar 4.31** Diagram Batang Rata-Rata (a) *Inflow* dan (b) *Outflow* Uang Kartal (Triliun) Menurut Hari Raya Idul Fitri di Kantor Perwakilan Bank Indonesia Provinsi Jawa Barat

Berdasarkan Gambar 4.31 (a) merupakan pergerakan *inflow* uang kartal pada saat dan sesudah hari raya Idul Fitri, sedangkan Gambar 4.31 (b) merupakan pergerakan *outflow* uang kartal pada sebelum dan saat hari raya Idul Fitri. Dari kedua gambar tersebut bisa diambil kesimpulan sebagai berikut.

### **1. Pergerakan *Inflow***

- a. Ketika hari raya idul Fitri jatuh pada minggu pertama. maka rata-rata *inflow* akan mengalami kenaikan pada saat bulan tersebut. Rata-rata *inflow* yang dihasilkan 8,5 Triliun sedangkan untuk satu bulan setelah hari raya Idul Fitri rata-rata yang dihasilkan menurun yaitu 4,2 Triliun. Dapat juga disimpulkan bahwa rata-rata *inflow* pada saat bulan hari raya Idul Fitri mencapai 2 kali lipat rata-rata *inflow* setelah hari raya Idul Fitri. apabila hari raya Idul Fitri terjadi pada minggu pertama.
- b. Sama dengan poin a. ketika hari raya idul Fitri jatuh pada minggu kedua, maka rata-rata *inflow* akan mengalami kenaikan pada saat bulan tersebut. Rata-rata *inflow* yang dihasilkan sebesar 5,8 Triliun sedangkan untuk satu bulan setelah hari raya Idul Fitri rata-rata yang dihasilkan menurun yaitu 3,6 Triliun.
- c. Berbeda dengan point a dan b, apabila hari raya idul Fitri jatuh pada minggu ketiga. maka rata-rata *inflow* pada saat dan sesudah hari raya Idul Fitri tidak berbeda jauh. Rata-rata *inflow* yang dihasilkan sebesar 5,5 Triliun sedangkan untuk satu bulan setelah hari raya Idul Fitri rata-rata yang dihasilkan tidak berbeda jauh yaitu sekitar 5,7 Triliun
- d. Ketika hari raya idul Fitri jatuh pada minggu keempat. maka rata-rata *inflow* akan mengalami kenaikan pada satu bulan setelah hari raya Idul Fitri. Hal tersebut merupakan kondisi yang berkebalikan pada point a dan b. yaitu ketika hari raya Idul Fitri yang jatuh pada minggu pertama dan kedua.

### **2. Pergerakan *Outflow***

- a. Ketika hari raya idul Fitri jatuh pada minggu pertama, maka rata-rata *outflow* akan mengalami kenaikan pada satu bulan sebelum hari raya Idul Fitri. Rata-rata *outflow* yang dihasilkan sebesar 7,1 Triliun, sedangkan rata-rata *outflow* saat hari raya


Idul Fitri yang dihasilkan menurun yaitu sekitar 1,3 Triliun. Dapat juga disimpulkan bahwa rata-rata *outflow* pada saat bulan hari raya Idul Fitri mengalami penurunan yang signifikan mencapai 7 kali lipat lebih rendah dari rata-rata *outflow* sebelum hari raya Idul Fitri, apabila hari raya Idul Fitri terjadi pada minggu pertama.

- b. Berbeda dengan poin a. ketika hari raya Idul Fitri jatuh pada minggu kedua, maka rata-rata *outflow* pada sebelum dan saat bulan hari raya Idul Fitri tidak berbeda jauh. Rata-rata *outflow* yang dihasilkan ketika satu bulan sebelum hari raya Idul Fitri sebesar 3 Triliun sedangkan untuk saat bulan hari raya Idul Fitri rata-rata yang dihasilkan tidak berbeda jauh yaitu sekitar 2,6 Triliun.
- c. Peningkatan rata-rata *outflow* ketika hari raya Idul Fitri jatuh pada minggu ketiga merupakan kondisi yang berbanding terbalik dengan poin a yang jatuh pada minggu pertama. Terlihat bahwa rata-rata *outflow* akan mengalami kenaikan ketika saat bulan terjadinya hari raya Idul Fitri. Rata-rata *outflow* pada satu bulan sebelum hari raya Idul Fitri sebesar 2,7 Triliun sedangkan untuk saat bulan hari raya Idul Fitri rata-rata yang dihasilkan mengalami kenaikan sekitar 5,2 Triliun.
- d. Ketika hari raya Idul Fitri jatuh pada minggu keempat, maka rata-rata *outflow* akan mengalami kenaikan pada saat bulan hari raya Idul Fitri. Hal tersebut merupakan kondisi yang sama pada point c, yaitu ketika hari raya Idul Fitri yang jatuh pada minggu ketiga.

#### 4.3 Model ARIMAX *Outflow* dan *Inflow* Uang Kartal

Sebelum pemodelan ARIMAX dilakukan, maka hal yang harus dilakukan adalah pemodelan regresi *time series* jika residual tidak memenuhi asumsi independen. Kemudian menentukan variabel *dummy* yang digunakan. Berdasarkan eksplorasi data, bahwa *inflow* dan *outflow* uang kartal di Bank Indonesia Jawa Barat memiliki efek variasi kalender hari raya Idul Fitri.

Selain pembentukan variabel *dummy* efek variasi kalender, *Inflow* dan *outflow* uang kartal di BI Jawa Barat merupakan kejadian musiman karena *inflow* uang kartal umumnya tinggi terjadi pada bulan Januari, sedangkan *outflow* uang kartal tinggi terjadi pada bulan Desember. Oleh karena itu, maka variabel *dummy* yang digunakan adalah *dummy* bulanan yaitu bulan Januari hingga bulan Desember serta variabel *dummy* yang menyatakan pola tren. Berdasarkan eksplorasi data, diduga terdapat tiga periode yang berbeda-beda pada pola data *inflow* dan *outflow* uang kartal karena adanya beberapa perubahan kebijakan yaitu periode pertama pada Januari 2003 hingga Desember 2006, periode kedua pada Januari 2007 hingga Desember 2010, dan periode ketiga pada Januari 2011 hingga Desember 2015. Secara visual ditampilkan pada Gambar 4.32.



**Gambar 4.32** Time Series Plot (a) *Inflow* dan (b) *Outflow* Uang Kartal

Berdasarkan Gambar 4.32, tampak bahwa terdapat tiga *trend* yang menguatkan adanya variabel *dummy* akibat dari perubahan kebijakan yang dikeluarkan oleh BI. Pola *dummy* untuk tiga periode tersebut ditampilkan pada Tabel 4.54.

$$I_{1,t} = \begin{cases} 1, & \text{untuk 2007 hingga 2010} \\ 0, & \text{untuk tahun yang lain} \end{cases}$$

$$I_{2,t} = \begin{cases} 1, & \text{untuk 2011 hingga 2015} \\ 0, & \text{untuk tahun yang lain} \end{cases}$$

$$tI_{1,t} = \begin{cases} 1t, & \text{untuk 2007 hingga 2010} \\ 0, & \text{untuk tahun yang lain} \end{cases}$$


$$tI_{2,t} = \begin{cases} 1t, & \text{untuk 2011 hingga 2015} \\ 0, & \text{untuk tahun yang lain} \end{cases}$$

**Tabel 4.54** Pola Dummy Variabel *Dummy* Kebijakan

Tahun	$t$	$I_{1,t}$	$I_{2,t}$	$tI_{1,t}$	$tI_{2,t}$
2003	1	0	0	0	0
2003	2	0	0	0	0
$\vdots$	$\vdots$	$\vdots$	$\vdots$	$\vdots$	$\vdots$
2006	36	0	0	0	0
2007	37	1	0	37	0
2007	38	1	0	38	0
$\vdots$	$\vdots$	$\vdots$	$\vdots$	$\vdots$	$\vdots$
2010	84	1	0	84	0
2011	85	0	1	0	85
2011	86	0	1	0	86
$\vdots$	$\vdots$	$\vdots$	$\vdots$	$\vdots$	$\vdots$
2015	144	0	1	0	144

### 4.3.1 Model ARIMAX *Outflow* Uang Kartal

Data *outflow* pada penelitian ini belum stasioner dalam varians. Hal tersebut dapat dilihat pada Gambar 4.33 dengan nilai *rounded value* sebesar 0.2 dengan batas atas sebesar 0,41 dan batas bawah sebesar 0,12.



**Gambar 4.33** Box-Cox Data *Outflow* Uang Kartal

Oleh karena itu, data *outflow* perlu distasionerkan terlebih dahulu sebelum dianalisis lebih lanjut menggunakan transformasi Box-Cox yang memiliki nilai *rounded value* sebesar 0,2 sehingga hasil tranformasi tersebut dapat dituliskan sebagai berikut.

$$Z_{1,t}^* = \frac{Z_{1,t}^{0.2} - 1}{0,2}$$

Tahap awal pembentukan model ARIMAX adalah mengacu pada pemodelan regresi *time series*. Berikut model *regresi time series* untuk data *outflow* uang kartal.

$$\begin{aligned} Z_{1,t}^* = & \delta t + \varphi_1 I_{1,t} + \varphi_2 I_{2,t} + \varphi_3 t I_{1,t} + \varphi_4 t I_{2,t} + \beta_1 M_{1,t} + \beta_2 M_{2,t} + \beta_3 M_{3,t} \\ & + \beta_4 M_{4,t} + \beta_5 M_{5,t} + \beta_6 M_{6,t} + \beta_7 M_{7,t} + \beta_8 M_{8,t} + \beta_9 M_{9,t} + \beta_{10} M_{10,t} \\ & + \beta_{11} M_{11,t} + \beta_{12} M_{12,t} + \gamma_1 D_{1,t} + \gamma_2 D_{2,t} + \gamma_3 D_{3,t} + \gamma_4 D_{4,t} + \alpha_1 D_{1,t-1} \\ & + \alpha_2 D_{2,t-1} + \alpha_3 D_{3,t-1} + \alpha_4 D_{4,t-1} \end{aligned}$$

Kemudian dilakukan estimasi parameter dari model regresi *time series* yang ditampilkan pada Tabel 4.55, sehingga persamaan regresi *time series* untuk data *outflow* uang kartal sebagai berikut.

$$\begin{aligned}
Z_{1,t}^* = & -0,001t - 2,893I_{1,t} - 2,617I_{2,t} + 0,025tI_{1,t} + 0,027tI_{2,t} - 0,01M_{1,t} \\
& + 0,245M_{2,t} + 0,511M_{3,t} + 0,776M_{4,t} + 0,592M_{5,t} + 0,932M_{6,t} \\
& + 0,681M_{7,t} + 0,307M_{8,t} + 0,482M_{9,t} + 0,338M_{10,t} + 0,484M_{11,t} \\
& + 1,366M_{12,t} - 0,485D_{1,t} + 1,466D_{2,t} + 1,402D_{3,t} + 1,674D_{4,t} \\
& + 1,849D_{1,t-1} + 1,188D_{2,t-1} + 0,240D_{3,t-1} + 0,156D_{4,t-1}
\end{aligned}$$

**Tabel 4.55** Estimasi Parameter Regresi *Time Series Outflow* Uang Kartal


Parameter	Estimasi	Standar Error	t-value	P-value
$\delta$	-0,001	0,007	-0,200	0,838
$\phi_1$	-2,893	0,313	-9,250	<,0001
$\phi_2$	-2,617	0,399	-6,550	<,0001
$\phi_3$	0,025	0,008	3,010	0,003
$\phi_4$	0,027	0,008	3,450	0,001
$\beta_1$	-0,100	0,183	-0,550	0,584
$\beta_2$	0,245	0,184	1,330	0,186
$\beta_3$	0,511	0,185	2,760	0,007
$\beta_4$	0,776	0,186	4,170	<,0001
$\beta_5$	0,592	0,187	3,160	0,002
$\beta_6$	0,932	0,191	4,880	<,0001
$\beta_7$	0,681	0,196	3,480	0,001
$\beta_8$	0,307	0,197	1,560	0,122
$\beta_9$	0,482	0,198	2,430	0,017
$\beta_{10}$	0,338	0,201	1,680	0,095
$\beta_{11}$	0,484	0,199	2,430	0,016
$\beta_{12}$	1,366	0,197	6,950	<,0001
$\gamma_1$	-0,485	0,317	-1,530	0,129
$\gamma_2$	1,466	0,261	5,610	<,0001
$\gamma_3$	1,402	0,226	6,210	<,0001
$\gamma_4$	1,674	0,264	6,340	<,0001
$\alpha_1$	1,849	0,318	5,810	<,0001
$\alpha_2$	1,188	0,262	4,540	<,0001
$\alpha_3$	0,240	0,226	1,060	0,291
$\alpha_4$	0,156	0,212	0,740	0,462

Persamaan pada model regresi *time series* untuk data *outflow* uang kartal menghasilkan residual yang belum *white noise* yang berarti residual mengandung autokorelasi, karena *p-value* yang kurang dari 0,05 . Hal ini ditampilkan pada Tabel 4.56.

**Tabel 4.56** Uji Asumsi *White Noise* Residual Regresi *Time Series Outflow*

Hingga Lag ke-	$\chi^2$	Df	<i>P-value</i>
6	12,93	6	0,0442
12	18,54	12	0,1003
18	30,12	18	0,0363
24	38,25	24	0,0326
30	45,92	30	0,0316
36	49,04	36	0,0722

Kemudian tahap pertama yang dilakukan ketika residual belum independen adalah pembentukan model ARIMA berdasarkan plot ACF dan PACF dari residual regresi *time series* guna mendapatkan model yang memenuhi asumsi independen yang ditampilkan pada Gambar 4.34.



**Gambar 4.34** Plot ACF dan PACF Residual Regresi *Time Series Outflow*

Berdasarkan plot ACF dan PACF pada Gambar 4.34, maka model ARIMA yang terbentuk adalah  $ARIMA([2],0,[1,13])(1,0,0)^{12}$ ,  $ARIMA([2],0,[1,13])(0,0,1)^{12}$ ,  $ARIMA([1,2,13,14],0,0)(1,0,0)^{12}$  dan  $ARIMA(1,0,[13])(0,0,1)^{12}$ . Model ARIMA yang diperoleh akan dilakukan pengujian signifikansi parameter dan asumsi residual independen. Hasil pengujian signifikansi parameter model ARIMA ditampilkan pada Tabel 4.57.



**Tabel 4.57** Estimasi Parameter dan Uji signifikansi Parameter

ARIMA	Parameter	Estimasi	<i>t-value</i>	<i>P-value</i>
([2],0,[1,13]) (1,0,0) <sup>12</sup>	$\theta_1$	0,230	2,83	0,0053
	$\theta_{13}$	0,287	3,53	0,0006
	$\phi_2$	0,188	2,18	0,031
	$\Phi_1$	0,200	2,33	0,021
([2],0,[1,13]) (0,0,1) <sup>12</sup>	$\theta_1$	0,224	2,76	0,0066
	$\theta_{13}$	0,289	3,54	0,0005
	$\theta_1$	-0,230	-2,71	0,0076
	$\phi_2$	0,185	2,15	0,0335
([1,2,13,14],0,0) (1,0,0) <sup>12</sup>	$\phi_1$	-0,166	-2,04	0,0433
	$\phi_2$	0,193	2,41	0,0173
	$\phi_{13}$	-0,225	-2,76	0,0066
	$\phi_{14}$	-0,215	-2,59	0,0107
	$\Phi_1$	0,197	2,29	0,0235
(1,0,[13]) (0,0,1) <sup>12</sup>	$\theta_{13}$	0,284	3,41	0,0009
	$\theta_1$	-0,199	-2,34	0,0205
	$\phi_1$	-0,194	-2,35	0,0201

Berdasarkan Tabel 4.57, bahwa semua parameter model ARIMA memiliki parameter yang signifikan dikarenakan *p-value* kurang dari 0,05 serta menghasilkan residual yang independen, hal itu dijelaskan pada Tabel 4.58 bahwa semua nilai *p-value* tidak ada yang kurang dari 0,05 .

**Tabel 4.58** Uji Asumsi Independen

Hingga Lag ke-	ARIMA ([2],0,[1,13]) (1,0,0) <sup>12</sup>			ARIMA ([2],0,[1,13]) (1,0,0) <sup>12</sup>		
	$\chi^2$	Df	<i>P-value</i>	$\chi^2$	df	<i>P-value</i>
6	2,29	2	0,3188	2,24	2	0,3258
12	4,83	8	0,7756	4,91	8	0,7672
18	12,34	14	0,5791	12,57	14	0,5605
24	20,4	20	0,4331	19,85	20	0,4674
30	23,28	26	0,617	22,86	26	0,6409
36	28,81	32	0,6289	28,67	32	0,636

**Tabel 4.58** Uji Asumsi Independen (lanjutan)

Hingga Lag ke-	ARIMA ([1,2,13,14],0,0) (1,0,0) <sup>12</sup>			ARIMA (1,0,[13]) (0,0,1) <sup>12</sup>		
	$\chi^2$	df	P-value	$\chi^2$	df	P-value
6	1,9	1	0,1684	4,69	3	0,196
12	4,91	7	0,6712	7,36	9	0,6002
18	8,68	13	0,7966	19,23	15	0,2033
24	17,17	19	0,5784	26,85	21	0,1759
30	21,15	25	0,684	31,73	27	0,2422
36	25,14	31	0,7615	37,68	33	0,2636

Keempat model ARIMA yang sudah memenuhi asumsi independen dan memiliki parameter yang signifikan tersebut akan dianalisis membentuk model ARIMAX. Model pertama yang akan dianalisis adalah model ARIMA([1,2,13,14],0,0)(1,0,0)<sup>12</sup> yang mengikuti persamaan berikut.

$$\hat{a}_t = -0,166a_{t-1} + 0,193a_{t-2} + 0,197a_{t-12} - 0,192a_{t-13} - 0,253a_{t-14} \\ + 0,044a_{t-25} + 0,042a_{t-26}$$

Tahap selanjutnya adalah membentuk model ARIMAX yang merupakan gabungan antara model ARIMA dan model regresi *time series* variasi kalender kemudian diestimasi secara simultan. Berdasarkan estimasi parameter yang telah dilakukan pada Tabel 4.59, maka model ARIMAX dengan efek variasi kalender menggunakan semua parameter baik parameter yang signifikan atau tidak signifikan sebagai berikut.

$$Z_{1,t}^* = -0,005t - 2,723I_{1,t} - 2,568I_{2,t} + 0,025tI_{1,t} + 0,029tI_{2,t} - 0,001M_{1,t} \\ + 0,273M_{2,t} + 0,569M_{3,t} + 0,846M_{4,t} + 0,648M_{5,t} + 0,926M_{6,t} \\ + 0,720M_{7,t} + 0,383M_{8,t} + 0,581M_{9,t} + 0,487M_{10,t} + 0,606M_{11,t} \\ + 1,372M_{12,t} - 0,703D_{1,t} + 1,495D_{2,t} + 1,126D_{3,t} + 1,540D_{4,t} \\ + 1,632D_{1,t-1} + 1,083D_{2,t-1} + 0,286D_{3,t-1} + 0,472D_{4,t-1} \\ + \frac{1}{(1 + 0,199B - 0,24B^2 + 0,323B^{13} + 0,242B^{14})(1 - 0,207B^{12})} a_t$$

**Tabel 4.59** Hasil Estimasi Parameter ARIMAX Menggunakan Semua Parameter dengan Efek Variasi Kalender *Outflow* Uang Kartal

Parameter	Estimasi	Standar Error	<i>t-value</i>	<i>P-value</i>
$\phi_1$	-0,199	0,090	-2,22	0,0286
$\phi_2$	0,240	0,088	2,74	0,0071
$\phi_3$	-0,323	0,088	-3,66	0,0004
$\phi_4$	-0,242	0,092	-2,64	0,0094
$\Phi_1$	0,207	0,098	2,12	0,0366
$\delta$	-0,005	0,006	-0,82	0,4162
$\varphi_1$	-2,723	0,254	-10,73	<,0001
$\varphi_2$	-2,568	0,326	-7,87	<,0001
$\varphi_3$	0,025	0,007	3,65	0,0004
$\varphi_4$	0,029	0,007	4,45	<,0001
$\beta_1$	0,001	0,191	0,00	0,9976
$\beta_2$	0,273	0,195	1,40	0,1639
$\beta_3$	0,569	0,197	2,89	0,0046
$\beta_4$	0,846	0,198	4,28	<,0001
$\beta_5$	0,648	0,199	3,25	0,0015
$\beta_6$	0,926	0,203	4,57	<,0001
$\beta_7$	0,720	0,205	3,50	0,0007
$\beta_8$	0,383	0,206	1,86	0,0653
$\beta_9$	0,581	0,206	2,82	0,0057
$\beta_{10}$	0,487	0,211	2,31	0,0229
$\beta_{11}$	0,606	0,206	2,94	0,004
$\beta_{12}$	1,372	0,206	6,65	<,0001
$\gamma_1$	-0,703	0,265	-2,65	0,0092
$\gamma_2$	1,495	0,224	6,68	<,0001
$\gamma_3$	1,126	0,200	5,64	<,0001
$\gamma_4$	1,540	0,235	6,55	<,0001
$\alpha_1$	1,632	0,275	5,94	<,0001
$\alpha_2$	1,083	0,230	4,71	<,0001
$\alpha_3$	0,286	0,201	1,42	0,1571
$\alpha_4$	0,472	0,197	2,40	0,0182

Kemudian dilakukan pengujian Kolmogorov-Smirnov (KS) pada residual model ARIMAX dengan efek variasi kalender. Hasil

pengujian, menyimpulkan bahwa residual sudah memenuhi asumsi berdistribusi normal dengan  $p$ -value lebih besar 0,150 serta nilai  $D= 0,046$ .

Tahap selanjutnya adalah mengeliminasi parameter yang tidak signifikan pada model ARIMAX yang ditampilkan pada Tabel 4.60.

**Tabel 4.60** Hasil Estimasi Parameter ARIMAX yang Telah Signifikan dengan Efek Variasi Kalender *Outflow* Uang Kartal

Parameter	Estimasi	Standar Error	$t$ -value	$P$ -value
$\phi_1$	-0,191	0,090	-2,120	0,036
$\phi_2$	0,198	0,088	2,250	0,026
$\phi_3$	-0,254	0,088	-2,880	0,005
$\phi_4$	-0,233	0,091	-2,560	0,012
$\Phi_1$	0,312	0,093	3,360	0,001
$\varphi_1$	-2,744	0,248	-11,070	<,0001
$\varphi_2$	-2,449	0,330	-7,430	<,0001
$\varphi_3$	0,023	0,004	5,730	<,0001
$\varphi_4$	0,025	0,003	8,760	<,0001
$\beta_3$	0,482	0,175	2,760	0,007
$\beta_4$	0,680	0,179	3,790	0,000
$\beta_5$	0,537	0,183	2,930	0,004
$\beta_6$	0,849	0,178	4,770	<,0001
$\beta_7$	0,727	0,181	4,020	<,0001
$\beta_9$	0,609	0,180	3,390	0,001
$\beta_{11}$	0,478	0,175	2,730	0,007
$\beta_{12}$	1,111	0,173	6,420	<,0001
$\gamma_2$	1,707	0,225	7,580	<,0001
$\gamma_3$	1,344	0,209	6,420	<,0001
$\gamma_4$	1,715	0,241	7,100	<,0001
$\alpha_1$	1,628	0,280	5,820	<,0001
$\alpha_2$	0,954	0,230	4,150	<,0001

Berdasarkan Tabel 4.60, model persamaan ARIMAX yang menggunakan parameter signifikan saja sebagai berikut.

$$\begin{aligned}
Z_{1,t}^* = & -2,744I_{1,t} - 2,449I_{2,t} + 0,023tI_{1,t} + 0,482M_{3,t} + 0,680M_{4,t} \\
& + 0,537M_{5,t} + 0,849M_{6,t} + 0,727M_{7,t} + 0,609M_{9,t} + 0,478M_{11,t} \\
& + 1,111M_{12,t} + 1,707D_{2,t} + 1,344D_{3,t} + 1,715D_{4,t} + 1,628D_{1,t-1} \\
& + 0,954D_{2,t-1} \\
& + \frac{1}{(1 + 0,191B - 0,198B^2 + 0,254B^{13} + 0,233B^{14})(1 - 0,312B^{12})} a_t
\end{aligned}$$

Analisis selanjutnya adalah membandingkan kebaikan model berdasarkan RMSE *out-sample*. Perbandingan antara model ARIMAX yang menggunakan semua parameter dan hanya memuat parameter yang signifikan saja pada Tabel 4.61.

**Tabel 4.61** Perbandingan Hasil Ramalan Model ARIMAX Menggunakan Semua Parameter dan Memuat Parameter Signifikan *Outflow* Uang Kartal

Model ARIMAX	RMSE	
	<i>In-sample</i>	<i>Out-sample</i>
Semua Parameter	0,584704	<b>1,2803</b>
Parameter Signifikan	0,635764	1,40207

Berdasarkan Tabel 4.61, bahwa model ARIMAX menggunakan semua parameter memberikan hasil ramalan yang lebih baik untuk meramalkan *outflow* 12 bulan kedepan dengan nilai RMSE *out-sample* sebesar 1.2803. Hal tersebut mengacu pada pernyataan Hyndman dan Kostenko (2008), maka model yang digunakan untuk meramalkan *outflow* 12 bulan kedepan adalah ARIMAX menggunakan semua parameter.

Dengan cara yang sama, pemodelan ARIMA yang sudah diperoleh yaitu model ARIMA ([2],0,[1,13])(1,0,0)<sup>12</sup>, ARIMA ([2],0,[1,13])(0,0,1)<sup>12</sup>, dan model ARIMA (1,0,[13])(0,0,1)<sup>12</sup>, akan dianalisis membentuk model ARIMAX. Sehingga diperoleh nilai kebaikan model dengan kriteria RMSE *out-sample* ditampilkan pada Tabel 4.62 yang menjelaskan bahwa model ARIMAX ke -3 merupakan model yang terbaik karena memiliki nilai RMSE *out-sample* yang paling kecil dibandingkan dengan model ARIMAX lainnya. Oleh karena itu model ARIMAX ke-3 merupakan model

terbaik yang bisa digunakan untuk meramalkan data *outflow* uang kartal hingga 12 bulan ke depan.

**Tabel 4.62** Perbandingan Hasil Ramalan Model ARIMAX *Outflow*

ARIMAX	ARIMA	RMSE	
		<i>In-sample</i>	<i>Out-Sample</i>
1	([2],0,[1,13]) (1,0,0) <sup>12</sup>	0,606263	1,41943
2	([2],0,[1,13]) (0,0,1) <sup>12</sup>	0,599909	1,46125
3	([1,2,13,14],0,0) (1,0,0) <sup>12</sup>	<b>0,584704</b>	<b>1,28030</b>
4	(1,0,[13]) (0,0,1) <sup>12</sup>	0,599909	1,46125


Setelah memenuhi asumsi residual independen, dan berdistribusi normal maka akan dilanjutkan pengujian varians residual homogen dengan uji *Lagrange Multiplier* pada Tabel 4.63. hasil yang diperoleh adalah varians residual sudah memenuhi asumsi homogen karena semua *p-value* lebih dari 0,05

**Tabel 4.63** Uji Heteroskedastisitas Model ARIMAX *Outflow*

<i>K</i>	<i>Chi-Sq</i>	<i>p-value</i>
1	0,604	0,437
2	0,662	0,718
3	0,648	0,885
4	0,875	0,928
5	1,382	0,926
6	1,997	0,920
7	3,059	0,880
8	3,452	0,903
9	3,808	0,924
10	3,982	0,948
11	3,686	0,978
12	4,578	0,971

### 4.3.2 Model ARIMAX *Inflow* Uang Kartal

Data *inflow* pada penelitian ini belum stasioner dalam varians. Hal tersebut dapat dilihat pada Gambar 4.35 dengan nilai *rounded value* sebesar 0,0 dengan batas atas sebesar 0,33 dan batas bawah sebesar -0,11.



**Gambar 4.35** Box-Cox Data *Inflow* Uang Kartal

Oleh karena itu, data *inflow* perlu distasionerkan terlebih dahulu sebelum dianalisis lebih lanjut menggunakan transformasi Box-Cox yang memiliki nilai *rounded value* sebesar 0,0 sehingga hasil transformasi tersebut dapat dituliskan sebagai berikut.

$$Z_{2,t}^* = \ln(Z_{2,t})$$

Tahap awal pembentukan model ARIMAX adalah mengacu pada pemodelan regresi *time series*. Berikut model *regresi time series* untuk data *inflow* uang kartal.

$$\begin{aligned} Z_{2,t}^* = & \delta t + \varphi_1 I_{1,t} + \varphi_2 I_{2,t} + \varphi_3 I_{1,t} + \varphi_4 I_{2,t} + \beta_1 M_{1,t} + \beta_2 M_{2,t} + \beta_3 M_{3,t} \\ & + \beta_4 M_{4,t} + \beta_5 M_{5,t} + \beta_6 M_{6,t} + \beta_7 M_{7,t} + \beta_8 M_{8,t} + \beta_9 M_{9,t} + \beta_{10} M_{10,t} \\ & + \beta_{11} M_{11,t} + \beta_{12} M_{12,t} + \gamma_1 D_{1,t} + \gamma_2 D_{2,t} + \gamma_3 D_{3,t} + \gamma_4 D_{4,t} + \omega_1 D_{1,t+1} \\ & + \omega_2 D_{2,t+1} + \omega_3 D_{3,t+1} + \omega_4 D_{4,t+1} \end{aligned}$$

Kemudian dilakukan estimasi parameter dari model regresi *time series*. Hasil estimasi parameter tersebut pada Tabel 4.64.

**Tabel 4.64** Estimasi Parameter Regresi *Time Series Inflow* Uang Kartal

Parameter	Estimasi	Standar Error	t-value	P-value
$\delta$	-0,005	0,002	-2,35	0,0204
$\varphi_1$	-1,952	0,178	-10,97	<,0001
$\varphi_2$	-0,839	0,242	-3,46	0,0007
$\varphi_3$	0,023	0,004	6,52	<,0001
$\varphi_4$	0,017	0,003	5,39	<,0001
$\beta_1$	1,570	0,098	15,97	<,0001
$\beta_2$	1,212	0,099	12,28	<,0001
$\beta_3$	1,240	0,094	13,23	<,0001
$\beta_4$	1,111	0,094	11,82	<,0001
$\beta_5$	1,127	0,094	11,95	<,0001
$\beta_6$	1,104	0,095	11,68	<,0001
$\beta_7$	1,244	0,097	12,85	<,0001
$\beta_8$	1,279	0,099	12,92	<,0001
$\beta_9$	1,173	0,099	11,81	<,0001
$\beta_{10}$	1,314	0,101	13,05	<,0001
$\beta_{11}$	1,223	0,102	12,00	<,0001
$\beta_{12}$	0,879	0,099	8,88	<,0001
$\gamma_1$	0,962	0,189	5,09	<,0001
$\gamma_2$	0,610	0,155	3,93	0,0001
$\gamma_3$	0,189	0,134	1,42	0,1595
$\gamma_4$	-0,275	0,155	-1,78	0,0784
$\omega_1$	0,318	0,188	1,69	0,0944
$\omega_2$	0,345	0,155	2,22	0,028
$\omega_3$	0,461	0,134	3,45	0,0008
$\omega_4$	0,538	0,135	4,00	0,0001

Berdasarkan Tabel 4.64, maka persamaan regresi *time series* untuk data *inflow* uang kartal dapat dituliskan sebagai berikut.

$$\begin{aligned}
 Z_{2,t}^* = & -0,005t - 1,952I_{1,t} - 0,839I_{2,t} + 0,023tI_{1,t} + 0,017tI_{2,t} + 1,57M_{1,t} \\
 & + 1,212M_{2,t} + 1,24M_{3,t} + 1,111M_{4,t} + 1,127M_{5,t} + 1,104M_{6,t} \\
 & + 1,244M_{7,t} + 1,279M_{8,t} + 1,173M_{9,t} + 1,314M_{10,t} + 1,223M_{11,t} \\
 & + 0,879M_{12,t} + 0,962D_{1,t} + 0,610D_{2,t} + 0,189D_{3,t} - 0,275D_{4,t} \\
 & + 0,318D_{1,t+1} + 0,345D_{2,t+1} + 0,461D_{3,t+1} + 0,538D_{4,t+1}
 \end{aligned}$$

Persamaan pada model regresi *time series* diatas, menghasilkan




residual yang belum *white noise* karena *p-value* yang kurang dari 0,05 . Hal tersebut ditampilkan pada Tabel 4.65.

**Tabel 4.65** Uji Asumsi White Noise Residual Regresi *Time Series Inflow*

Hingga Lag ke-	$\chi^2$	Df	<i>P-value</i>
6	16,98	6	0,0093
12	22,25	12	0,0348
18	27,13	18	0,0766
24	44,42	24	0,0068
30	54,66	30	0,0039
36	56,88	36	0,0148

Kemudian tahap pertama yang dilakukan ketika residual belum independen adalah pembentukan model ARIMA berdasarkan plot ACF dan PACF dari residual regresi *time series* guna mendapatkan model yang memenuhi asumsi independen yang ditampilkan pada Gambar 4.36.



**Gambar 4.36** Plot ACF dan PACF Residual Regresi *Time Series Inflow*

Berdasarkan plot ACF dan PACF pada Gambar 4.36, maka model ARIMA yang terbentuk adalah  $ARIMA([3],0,0)(0,0,1)^{24}$  dan  $ARIMA(0,0,[3,16])(1,0,0)^{24}$ . Model ARIMA yang diperoleh akan dilakukan pengujian signifikansi parameter dan asumsi residual independen. Hasil pengujian tersebut ditampilkan pada Tabel 4.66.

**Tabel 4.66** Estimasi Parameter dan Uji signifikansi Parameter ARIMA

ARIMA	Parameter	Estimasi	<i>t-value</i>	<i>P-value</i>
([3],0,0) (0,0,1) <sup>24</sup>	$\Theta_1$	0.216	2.53	0.0125
	$\phi_3$	0.244	2.99	0.0033
	$\theta_3$	-0.220	-2.7	0.0077
(0,0,[3,16])(1,0,0) <sup>24</sup>	$\theta_{16}$	0.173	2.08	0.0389
	$\Phi_1$	-0.184	-2.14	0.034

Berdasarkan Tabel 4.66, bahwa semua parameter model ARIMA memiliki parameter yang signifikan dikarenakan *p-value* kurang dari 0,05 serta menghasilkan residual yang independen, hal itu dijelaskan pada Tabel 4.67 bahwa semua nilai *p-value* tidak ada yang kurang dari 0,05 .

**Tabel 4.67** Uji Asumsi Independen

Hingga Lag ke-	ARIMA ([3],0,0) (0,0,1) <sup>24</sup>			ARIMA (0,0,[3,16])(1,0,0) <sup>24</sup>		
	$\chi^2$	Df	<i>P-value</i>	$\chi^2$	Df	<i>P-value</i>
6	2,14	4	0,7097	2,9	3	0,4071
12	8,13	10	0,6163	6,96	9	0,6408
18	12,52	16	0,7072	8,16	15	0,9172
24	18,69	22	0,6643	13,53	21	0,8889
30	25,75	28	0,5865	19,61	27	0,8467
36	32,02	34	0,5649	24,97	33	0,8411

Kedua model ARIMA yang sudah memenuhi asumsi independen dan memiliki parameter yang signifikan tersebut akan dianalisis membentuk model ARIMAX. Model pertama yang akan dianalisis adalah model ARIMA([3],0,0)(0,0,1)<sup>24</sup> yang mengikuti persamaan berikut.

$$\hat{a}_t = 0,244a_{t-3} - 0,216a_{t-24}$$

Tahap selanjutnya adalah membentuk model ARIMAX yang merupakan gabungan antara model ARIMA dan model regresi *time series* variasi kalender kemudian diestimasi secara simultan pada Tabel 4.68.

**Tabel 4.68** Estimasi Parameter ARIMAX dengan Semua Parameter dengan Efek Variasi Kalender *Inflow* Uang Kartal

Parameter	Estimasi	Standar Error	<i>t-value</i>	<i>P-value</i>
$\Theta_1$	0,238	0,102	2,33	0,0215
$\phi_3$	0,308	0,091	3,37	0,001
$\delta$	-0,005	0,002	-1,92	0,0567
$\rho_1$	-1,872	0,227	-8,26	<,0001
$\rho_2$	-0,849	0,317	-2,68	0,0085
$\rho_3$	0,022	0,004	5,28	<,0001

**Tabel 4.68** Estimasi Parameter ARIMAX dengan Semua Parameter dengan Efek Variasi Kalender *Inflow* Uang Kartal (lanjutan)

Parameter	Estimasi	Standar Error	<i>t-value</i>	<i>P-value</i>
$\varphi_4$	0,016	0,004	4,36	<,0001
$\beta_1$	1,544	0,095	16,19	<,0001
$\beta_2$	1,185	0,096	12,41	<,0001
$\beta_3$	1,223	0,089	13,69	<,0001
$\beta_4$	1,084	0,090	12,00	<,0001
$\beta_5$	1,101	0,090	12,17	<,0001
$\beta_6$	1,072	0,091	11,75	<,0001
$\beta_7$	1,223	0,092	13,31	<,0001
$\beta_8$	1,272	0,093	13,61	<,0001
$\beta_9$	1,150	0,095	12,14	<,0001
$\beta_{10}$	1,314	0,095	13,9	<,0001
$\beta_{11}$	1,223	0,096	12,77	<,0001
$\beta_{12}$	0,871	0,094	9,22	<,0001
$\gamma_1$	0,862	0,171	5,04	<,0001
$\gamma_2$	0,563	0,141	4,00	0,0001
$\gamma_3$	0,215	0,118	1,82	0,0719
$\gamma_4$	-0,390	0,140	-2,79	0,0061
$\omega_1$	0,108	0,170	0,63	0,5283
$\omega_2$	0,369	0,142	2,6	0,0107
$\omega_3$	0,407	0,119	3,43	0,0008
$\omega_4$	0,537	0,121	4,46	<,0001

Berdasarkan Tabel 4.68, berikut persamaan model ARIMAX menggunakan semua parameter dengan efek variasi kalender.

$$\begin{aligned}
 Z_{2,t}^* = & -0,005t - 1,872I_{1,t} - 0,849I_{2,t} + 0,022tI_{1,t} + 0,016tI_{2,t} - 1,544M_{1,t} \\
 & + 1,185M_{2,t} + 1,223M_{3,t} + 1,084M_{4,t} + 1,101M_{5,t} + 1,072M_{6,t} \\
 & + 1,223M_{7,t} + 1,272M_{8,t} + 1,150M_{9,t} + 1,314M_{10,t} + 1,223M_{11,t} \\
 & + 0,871M_{12,t} - 0,862D_{1,t} + 0,563D_{2,t} + 0,215D_{3,t} - 0,390D_{4,t} \\
 & + 0,108D_{1,t+1} + 0,369D_{2,t+1} + 0,407D_{3,t+1} + 0,537D_{4,t+1} \\
 & + \frac{(1 - 0,238B^{24})}{(1 - 0,308B^3)} a_t
 \end{aligned}$$

Kemudian dilakukan pengujian Kolmogorov Smirnov (KS) pada residual model ARIMAX dengan efek variasi kalender. Hasil pengujian, menyimpulkan bahwa residual sudah memenuhi asumsi berdistribusi normal dengan  $p$ -value sebesar  $> 0.150$  serta nilai  $D = 0,053$ .

Tahap selanjutnya adalah mengeliminasi parameter yang tidak signifikan pada model ARIMAX pada Tabel 4.69.

**Tabel 4.69** Hasil Estimasi Parameter ARIMAX yang Telah Signifikan dengan Efek Variasi Kalender *Inflow* Uang Kartal

Parameter	Estimasi	Standar Error	$t$ -value	$P$ -value
$\Theta_1$	0,263	0,09863	2,67	0,0087
$\phi_3$	0,314	0,08981	3,5	0,0007
$\varphi_1$	-1,784	0,22775	-7,83	<,0001
$\varphi_2$	-0,698	0,32204	-2,17	0,0322
$\varphi_3$	0,017	0,00354	4,92	<,0001
$\varphi_4$	0,011	0,002735	3,99	0,0001
$\beta_1$	1,421	0,07066	20,11	<,0001
$\beta_2$	1,060	0,0706	15,02	<,0001
$\beta_3$	1,122	0,07368	15,23	<,0001
$\beta_4$	0,982	0,07346	13,36	<,0001
$\beta_5$	0,997	0,07336	13,59	<,0001
$\beta_6$	0,966	0,07307	13,23	<,0001
$\beta_7$	1,135	0,07509	15,11	<,0001
$\beta_8$	1,190	0,07646	15,56	<,0001
$\beta_9$	1,064	0,0763	13,95	<,0001
$\beta_{10}$	1,216	0,07834	15,52	<,0001
$\beta_{11}$	1,141	0,07536	15,15	<,0001
$\beta_{12}$	0,770	0,07332	10,5	<,0001
$\gamma_1$	0,848	0,17246	4,92	<,0001
$\gamma_2$	0,541	0,1429	3,78	0,0002
$\gamma_4$	-0,424	0,14117	-3	0,0033
$\omega_2$	0,370	0,14428	2,57	0,0115
$\omega_3$	0,391	0,12064	3,24	0,0015
$\omega_4$	0,542	0,12255	4,43	<,0001

Berdasarkan Tabel 4.69, persamaan untuk model ARIMAX menggunakan parameter signifikan saja sebagai berikut.

$$\begin{aligned}
Z_{2,t}^* = & -1,784I_{1,t} - 0,698I_{2,t} + 0,017I_{1,t} + 0,011I_{2,t} + 1,421M_{1,t} \\
& + 1,060M_{2,t} + 1,122M_{3,t} + 0,982M_{4,t} + 0,997M_{5,t} \\
& + 0,966M_{6,t} + 1,135M_{7,t} + 1,190M_{8,t} + 1,064M_{9,t} \\
& + 1,216M_{10,t} + 1,141M_{11,t} + 0,770M_{12,t} + 0,848D_{1,t} \\
& + 0,541D_{2,t} - 0,424D_{4,t} + 0,370D_{2,t+1} + 0,391D_{3,t+1} \\
& + 0,542D_{4,t+1} + \frac{(1-0,263B^{24})}{(1-0,314B^3)} a_t
\end{aligned}$$

Analisis selanjutnya adalah membandingkan kebaikan model berdasarkan RMSE *out-sample*. Perbandingan antara model ARIMAX yang menggunakan semua parameter dan hanya memuat parameter yang signifikan saja pada Tabel 4.70.

**Tabel 4.70** Perbandingan Hasil Ramalan Model ARIMAX Menggunakan Semua Parameter dan Memuat Parameter Signifikan Pada *Inflow* Uang Kartal

Model ARIMAX	RMSE	
	<i>In-sample</i>	<i>Out-sample</i>
Semua Parameter	0,719269	1,89867
Parameter Signifikan	0,781342	<b>1,85148</b>

Berdasarkan Tabel 4.70, bahwa model ARIMAX menggunakan parameter signifikan saja memberikan hasil ramalan yang lebih baik untuk meramalkan *inflow* hingga 12 bulan kedepan dengan nilai RMSE *out-sample* sebesar 1,85148. Sehingga, model ARIMAX yang akan digunakan untuk peramalan *inflow* hingga 12 bulan kedepan adalah menggunakan parameter yang signifikan saja.

Dengan cara yang sama, pemodelan ARIMA yang sudah didapatkan yaitu model ARIMA (0,0,[3,16])(1,0,0)<sup>24</sup>, akan dianalisis membentuk model ARIMAX. Sehingga diperoleh nilai kebaikan model dengan kriteria RMSE *out-sample* ditampilkan pada Tabel 4.71 yang menjelaskan bahwa model ARIMAX ke-1 merupakan model yang terbaik karena memiliki nilai RMSE *out-sample* yang paling kecil dibandingkan dengan model ARIMAX lainnya.

**Tabel 4.71** Perbandingan Hasil Ramalan Model ARIMAX *Inflow*

ARIMAX	ARIMA	RMSE	
		<i>In-sample</i>	<i>Out-Sample</i>
1	$([3],0,0)(0,0,1)^{24}$	0.781342	<b>1.85148</b>
2	$(0,0,[3,16])(1,0,0)^{24}$	0.706647	1.88846


Setelah memenuhi asumsi residual independen, dan berdistribusi normal maka akan dilanjutkan pengujian varians residual homogen dengan uji *Lagrange Multiplier* pada Tabel 4.72.

**Tabel 4.72** Uji Heteroskedastisitas Model ARIMAX *Inflow*

<i>k</i>	<i>Chi-Sq</i>	<i>p-value</i>
1	1,6963	0,1928
2	2,2773	0,3203
3	2,7724	0,4281
4	3,1149	0,5388
5	3,0125	0,6981
6	2,9549	0,8145
7	2,8794	0,8959
8	2,8209	0,9451
9	3,2292	0,9545
10	3,9525	0,9495
11	27,5819	0,0038
12	30,1597	0,0026

Berdasarkan Tabel 4.72, hasil pengujian *Lagrange Multiplier* untuk model ARIMAX dengan efek variasi kalender *inflow* uang kartal, menunjukkan bahwa varians residual tidak homogen karena terdapat *p-value* yang kurang dari 0,05. Sehingga perlu dilakukan pemodelan ARCH.

Tahap pertama yang dilakukan untuk pemodelan ARCH adalah menentukan orde ARCH. Penentuan orde berdasarkan lag yang signifikan terhadap plot ACF dan PACF residual kuadrat. Plot ACF dan PACF residual kuadrat pada model ARIMAX *Inflow* uang kartal ditampilkan pada Gambar 4.37.



**Gambar 4.37** Plot ACF dan PACF Residual Kuadrat Model ARIMAX *Inflow* Uang Kartal

Berdasarkan Gambar 4.37, model ARCH yang terbentuk adalah ARCH ([11]). Sehingga model ARCH dapat ditulis sebagai berikut

$\hat{\sigma}_t^2 = \hat{\theta}_0 + \hat{\theta}_{11} n_{t-11}^2$ . Kemudian, melakukan estimasi parameter yang ditampilkan pada Tabel 4.73. Berdasarkan Tabel 4.73, menunjukkan hasil parameter ARCH yang signifikan, karena *p-value* pada model ARCH ([11]) kurang dari 0,05.

**Tabel 4.73** Hasil Estimasi Parameter ARCH

Model	Parameter	Estimasi	Standard Error	t-value	p-value
ARCH ([11])	$\theta_0$	0,3916	0,0531	7,38	<,0001
	$\theta_{11}$	0,4194	0,1725	2,43	0,015


Setelah dilakukan estimasi parameter, maka persamaan ARCH ([11]) menjadi  $\hat{\sigma}_t^2 = 0,3916 + 0,4194 n_{t-11}^2$ . Meskipun residual tidak memenuhi asumsi homogen, model ARCH tersebut hanya akan berpengaruh pada terhadap penentuan batas atas dan batas bawah untuk ramalan interval. Batas atas dan bawah dapat diperoleh dari  $\hat{Z}_t \pm 1,96\sqrt{\hat{\sigma}_t^2}$  dengan  $\hat{\sigma}_t^2$  merupakan model ARCH.

#### 4.4 Model Neural Network Outflow dan Inflow Uang Kartal

Peramalan dengan menggunakan metode *Neural Network* bergantung pada pola hubungan antara *neuron* bisa disebut arsitektur jaringan serta fungsi aktivasi yang digunakan. Pada penelitian ini menggunakan arsitektur jaringan satu *hidden layer* dengan kombinasi *hidden neuron* yaitu 1, 2, 3, 4, 5, 10, dan 15 *neuron*. Kemudian fungsi aktivasi yang digunakan adalah sigmoid pada *hidden layer* dan *identity* pada *output layer*. Pada penentuan input berdasarkan lag-lag yang keluar dari PACF.

##### 4.4.1 Model Neural Network Outflow Uang Kartal

Pada pemodelan *Neural Network* input yang digunakan adalah lag-lag yang keluar pada PACF. Berikut PACF *Outflow* uang kartal ditampilkan pada Gambar 4.38.



**Gambar 4.38** Plot PACF *Outflow* Uang Kartal

Berdasarkan Gambar 4.38, lag yang signifikan pada plot PACF adalah lag 1, 2, 3, 5, 7, 11, 12, 13, dan 14. Kemudian dilakukan pengujian hubungan antar variabel dengan uji Terasvirta diperoleh *p-value* sebesar  $2,2 \cdot 10^{-16}$ , yang berarti hubungan antar variabel input bersifat non-linier. Selanjutnya, untuk mendapatkan arsitektur *Neural Network* yang optimal maka dilakukan kombinasi *hidden neuron* yaitu 1, 2, 3, 4, 5, 10, dan 15 *neuron*. Berikut akurasi peramalan menggunakan *Neural Network* pada Tabel 4.74.



**Tabel 4.74** Akurasi Peramalan Model *Neural Network Outflow*

Hidden Neuron	RMSE	
	In-sample	Out-sample
1	0,928	4,073
2	0,827	<b>3,758</b>
3	0,771	4,019
4	0,717	4,137
5	0,704	4,146
10	0,954	4,015
15	0,700	4,217


Berdasarkan Tabel 4.74, model yang terbaik pada *Neural Network* berdasarkan RMSE *out-sample* terkecil dengan jumlah *hidden 2 neuron*. Arsitektur dan persamaan untuk model *Neural Network* dengan 9 input dan 2 *hidden neuron* sebagai berikut.

$$\hat{Z}_{1,t} = 1,045 - 1,329f_1^h - 0,460f_2^h$$

dengan

$$f_1^h = [1 + \exp(-[1,092 + 0,753Z_{t-1} - 0,228Z_{t-2} + \dots + 0,723Z_{t-14}])]^{-1}$$

$$f_2^h = [1 + \exp(-[-2,735 - 8,868Z_{t-1} - 11,546Z_{t-2} + \dots + 1,839Z_{t-14}])]^{-1}$$




Error: 0.426995 Steps: 856

**Gambar 4.39** Arsitektur Model Terbaik *Neural Network Outflow* Uang Kartal

#### 4.4.2 Model *Neural Network Inflow* Uang Kartal

Pada pemodelan *Neural Network* input yang digunakan adalah lag-lag yang keluar pada PACF. Berikut PACF *inflow* uang kartal ditampilkan pada Gambar 4.40.



**Gambar 4.40** Plot PACF *Inflow* Uang Kartal

Berdasarkan Gambar 4.40, lag yang signifikan pada plot PACF adalah lag 1, 2, 3, 5, 12, 13, dan 14. Kemudian dilakukan pengujian hubungan antar variabel dengan uji Terasvirta didapatkan *p-value* sebesar  $2.2 \cdot 10^{-16}$ , yang berarti hubungan antar variabel input bersifat non-linier. Selanjutnya, untuk mendapatkan arsitektur *Neural Network* yang optimal maka dilakukan kombinasi *hidden neuron* yaitu 1, 2, 3, 4, 5, 10, dan 15 *neuron*. Berikut akurasi peramalan menggunakan *Neural Network* pada Tabel 4.75.

**Tabel 4.75** Akurasi Peramalan Model *Neural Network Inflow*


<i>Hidden Neuron</i>	RMSE	
	<i>In-sample</i>	<i>Out-sample</i>
1	1,275	<b>3,032</b>
2	1,132	3,396
3	1,091	3,298
4	1,081	3,408
5	1,017	3,760
10	1,093	3,447
15	1,030	3,525

Berdasarkan Tabel 4.75, model yang terbaik pada *Neural Network* berdasarkan RMSE *out-sample* terkecil dengan jumlah *hidden* 1 *neuron*. Arsitektur dan Persamaan untuk model *Neural Network* dengan 7 input dan 1 *hidden neuron* sebagai berikut.

$$\hat{Z}_{2,t} = -0.25 - 1,01f_1^h$$

dengan

$$f_1^h = [1 + \exp(-[-0,99 + 0,76Z_{t-1} + 1,56Z_{t-2} + \dots - 1,02Z_{t-14}])]^{-1}$$



**Gambar 4.41** Arsitektur Model Terbaik *Neural Network Inflow* Uang Kartal

#### 4.5 Model *Hybrid Outflow* dan *Inflow* Uang Kartal

*Hybrid* ARIMAX-NN merupakan gabungan dari model linier yaitu ARIMAX dan model non-linier yaitu *Neural Network*. Tahapan awal dalam melakukan *Hybrid* ARIMAX-NN adalah mendapatkan model ARIMAX, kemudian residual dari model ARIMAX akan dimodelkan dengan menggunakan model non-linier yaitu *Neural Network*. Kemudian, langkah selanjutnya adalah menjumlahkan ramalan ARIMAX dan *Neural Network* serta menghitung nilai RMSE. Input yang digunakan dalam memodelkan *Hybrid* ARIMAX-NN berdasarkan model AR pada ARIMAX yang diapatkan pada subab sebelumnya.

#### 4.5.1 Model *Hybrid Outflow* Uang Kartal

Residual yang diperoleh dari model ARIMAX yaitu  $Z_{1,t} = \hat{Z}_{1,t} + e_{1,t}$  selanjutnya residual akan dimodelkan menggunakan *Neural Network* dengan input lag 1, lag 2, lag 12, lag 13, lag 14, lag 25, dan lag 26. Setelah mendapatkan ramalan residual langkah selanjutnya adalah menjumlahkan ramalan hasil ARIMAX dengan *Neural Network*. Berikut akurasi peramalan menggunakan *Hybrid ARIMAX-NN* pada Tabel 4.76.

**Tabel 4.76** Akurasi Peramalan Model *Hybrid ARIMAX-NN Outflow*

<i>Hidden Neuron</i>	RMSE	
	<i>In-sample</i>	<i>Out-sample</i>
1	0,561	1,344
2	0,511	1,278
3	0,482	<b>1,238</b>
4	0,510	1,357
5	0,460	1,341
10	0,476	1,312
15	0,494	1,312

Berdasarkan Tabel 4.76, model yang terbaik *Hybrid ARIMAX-NN* untuk data *outflow* uang kartal berdasarkan RMSE *out-sample* terkecil dengan jumlah *hidden 3 neuron*. Persamaan dan Arsitektur terbaik dari model *Neural Network* dengan 7 input dan 3 *hidden neuron* untuk memodelkan residual model ARIMAX ditampilkan pada Gambar 4.42.

$$\hat{N}_{1,t} = 0,291 + 0,255f_1^h + 0,280f_2^h - 0,362f_3^h$$

dengan

$$f_1^h = [1 + \exp(-[1,268 + 0,512a_{t-1} + 1,180a_{t-2} + \dots + 9,061a_{t-26}])]^{-1}$$


$$f_2^h = [1 + \exp(-[0,943 + 2,071a_{t-1} - 0,955a_{t-2} + \dots - 9,283a_{t-26}])]^{-1}$$

$$f_3^h = [1 + \exp(-[3,011 + 1,670a_{t-1} - 3,827a_{t-2} + \dots + 7,060a_{t-26}])]^{-1}$$

$$\begin{aligned} L_{1,t}^* = & -0,005t - 2,723I_{1,t} - 2,568I_{2,t} + 0,025tI_{1,t} + 0,029tI_{2,t} - 0,001M_{1,t} \\ & + 0,273M_{2,t} + 0,569M_{3,t} + 0,846M_{4,t} + 0,648M_{5,t} + 0,926M_{6,t} \\ & + 0,720M_{7,t} + 0,383M_{8,t} + 0,581M_{9,t} + 0,487M_{10,t} + 0,606M_{11,t} \\ & + 1,372M_{12,t} - 0,703D_{1,t} + 1,495D_{2,t} + 1,126D_{3,t} + 1,540D_{4,t} \\ & + 1,632D_{1,t-1} + 1,083D_{2,t-1} + 0,286D_{3,t-1} + 0,472D_{4,t-1} \\ & + \frac{1}{(1 + 0,199B - 0,24B^2 + 0,323B^{13} + 0,242B^{14})(1 - 0,207B^{12})} a_t \end{aligned}$$

Sehingga persamaan untuk peramalan *Hybrid* ARIMAX-NN data *outflow* uang kartal sebagai berikut.

$$\hat{Z}_{1,t} = \hat{L}_{1,t}^* + \hat{N}_{1,t}, \text{ dengan } \hat{L}_{1,t}^* = \frac{\hat{L}_{1,t}^{0,2} - 1}{0,2}.$$



**Gambar 4.42** Arsitektur Model Terbaik *Neural Network* Residual Model  
ARIMAX *Outflow* Uang Kartal

Kemudian dilakukan pengujian varians residual homogen dengan uji *Lagrange Multiplier* pada Tabel 4.77. Pada Tabel 4.77, memberikan kesimpulan bahwa varians residual sudah memenuhi asumsi homogen karena *p-value* lebih dari 0,05 pada lag 1 hingga lag 12.

**Tabel 4.77** Uji Heteroskedastisitas Model *Hybrid* ARIMAX-NN

<i>K</i>	<i>Chi-Sq</i>	<i>p-value</i>
1	0,237	0,626
2	0,244	0,885
3	0,251	0,969
4	0,267	0,992
5	0,691	0,983
6	0,883	0,990
7	1,323	0,988
8	1,707	0,989
9	1,825	0,994
10	1,824	0,998
11	1,779	0,999
12	1,793	1,000

#### 4.5.2 Model *Hybrid Inflow* Uang Kartal

Residual yang diperoleh model ARIMAX yaitu  $Z_{2,t} = \hat{Z}_{2,t} + e_{2,t}$  selanjutnya residual tersebut akan dimodelkan menggunakan *Neural Network* dengan input lag 3. Setelah mendapatkan ramalan residual, langkah selanjutnya adalah menjumlahkan ramalan hasil ARIMAX dengan ramalan *Neural Network*. Berikut akurasi peramalan menggunakan *Hybrid* ARIMAX-NN pada Tabel 4.78.

**Tabel 4.78** Akurasi Peramalan Model *Hybrid* ARIMAX-NN *Inflow*

<i>Hidden Neuron</i>	<b>RMSE</b>	
	<i>In-sample</i>	<i>Out-sample</i>
1	0,675	1,957
2	0,675	1,951
3	0,674	<b>1,939</b>
4	0,676	1,948
5	0,673	1,941
10	0,675	1,950
15	0,676	1,952

Berdasarkan Tabel 4.78, model yang terbaik *Hybrid* ARIMAX-NN untuk data *inflow* uang kartal berdasarkan RMSE *out-sample*

terkecil dengan jumlah *hidden 3 neuron*. Persamaan dan Arsitektur terbaik dari model *Neural Network* dengan 1 input dan 3 *hidden neuron* untuk memodelkan residual model ARIMAX ditampilkan pada Gambar 4.43.

$$\hat{N}_{2,t} = 0,800 - 1,566f_1^h + 0,689f_2^h - 1,036f_3^h$$

dengan

$$f_1^h = [1 + \exp(-[-1,546 + 1,233a_{t-3}])]^{-1}$$


$$f_2^h = [1 + \exp(-[-0,527 + 1,779a_{t-3}])]^{-1}$$

$$f_3^h = [1 + \exp(-[-0,854 + 0,152a_{t-3}])]^{-1}$$

$$\begin{aligned} L_{2,t}^* = & -1,784I_{1,t} - 0,698I_{2,t} + 0,017tI_{1,t} + 0,011tI_{2,t} + 1,421M_{1,t} \\ & + 1,060M_{2,t} + 1,122M_{3,t} + 0,982M_{4,t} + 0,997M_{5,t} \\ & + 0,966M_{6,t} + 1,135M_{7,t} + 1,190M_{8,t} + 1,064M_{9,t} \\ & + 1,216M_{10,t} + 1,141M_{11,t} + 0,770M_{12,t} + 0,848D_{1,t} \\ & + 0,541D_{2,t} - 0,424D_{4,t} + 0,370D_{2,t+1} + 0,391D_{3,t+1} \\ & + 0,542D_{4,t+1} + \frac{(1 - 0,263B^{24})}{(1 - 0,314B^3)} a_t \end{aligned}$$

Sehingga persamaan untuk peramalan *Hybrid ARIMAX-NN* data *inflow* uang kartal sebagai berikut.

$$\hat{Z}_{2,t} = \hat{L}_{2,t}^* + \hat{N}_{2,t}, \text{ dengan } \hat{L}_{2,t}^* = \ln(\hat{L}_{2,t})$$



**Gambar 4.43** Arsitektur Model Terbaik *Neural Network* Residual Model ARIMAX *Inflow* Uang Kartal

Kemudian dilakukan pengujian varians residual homogen dengan uji *Lagrange Multiplier* pada Tabel 4.79.

**Tabel 4.79** Uji Heteroskedastisitas Model *Hybrid* ARIMAX-NN

<i>k</i>	<i>Chi-Sq</i>	<i>p-value</i>
1	0,183	0,668
2	0,255	0,880
3	0,289	0,962
4	2,465	0,651
5	3,185	0,671
6	4,143	0,657
7	4,669	0,700
8	4,203	0,838
9	4,875	0,845
10	6,577	0,765
11	9,987	0,532
12	9,918	0,623

Berdasarkan Tabel 4.79, memberikan kesimpulan bahwa varians residual sudah memenuhi asumsi homogen karena *p-value* lebih dari 0,05 pada lag 1 hingga lag 12.



#### 4.6 Perbandingan Hasil Akurasi Peramalan

Setelah dilakukan analisis menggunakan metode ARIMAX, *Neural Network*, dan *Hybrid ARIMAX-NN* maka langkah selanjutnya adalah pemilihan metode terbaik dalam menganalisis *inflow* dan *outflow* uang kartal. Kriteria kebaikan model terbaik berdasarkan nilai RMSE *out-sample*. Hasil perbandingan dari setiap metode untuk data *outflow* dan *inflow* uang kartal pada Tabel 4.80.

**Tabel 4.80** Hasil Perbandingan RMSE *Outflow* dan *Inflow* Uang Kartal

Data	Metode	RMSE	
		<i>In-sample</i>	<i>Out-sample</i>
<i>Outflow</i>	ARIMAX	0,585	1,280
	<i>Neural Network</i>	0,827	3,986
	<i>Hybrid ARIMAX-NN</i>	0,482	1,238
<i>Inflow</i>	ARIMAX	0,781	1,851
	<i>Neural Network</i>	1,275	3,032
	<i>Hybrid ARIMAX-NN</i>	0,674	1,939

Pada Tabel 4.80, diperoleh hasil bahwa model terbaik untuk *outflow* uang kartal adalah *Hybrid ARIMAX-NN* dengan nilai RMSE *out-sample* sebesar 1,238 serta pada model *outflow* uang kartal memenuhi semua asumsi yaitu identik, independen, dan distribusi normal. Sedangkan model terbaik untuk *inflow* uang kartal adalah ARIMAX dengan nilai RMSE *out-sample* sebesar 1,851. Pada model *inflow* uang kartal tidak memenuhi asumsi identik, sehingga diduga model *hybrid* tidak lebih baik dibandingkan model ARIMAX. Kemudian dilakukan perhitungan rasio *benchmark* berdasarkan nilai RMSE *out-sample* pada Tabel 4.81.

**Tabel 4.81** Hasil Rasio *Benchmark Inflow* dan *Outflow*

Uang Kartal	NN	<i>Hybrid ARIMAX-NN</i>
<i>Outflow</i>	3.1133	0,9670
<i>Inflow</i>	1,6376	1,0473

Tabel 4.81 menunjukkan bahwa rasio *benchmark* pada *outflow* untuk *Hybrid* ARIMAX-NN sebesar 0,9670 yang berarti model *Hybrid* ARIMAX-NN mampu menurunkan kesalahan 3,3% dibandingkan model ARIMAX sedangkan rasio *benchmark* pada *inflow* uang kartal untuk *Hybrid* ARIMAX-NN sebesar 1,0473 yang berarti model *Hybrid* ARIMAX-NN meningkatkan kesalahan 4,73% dibandingkan model ARIMAX. Sehingga metode *Hybrid* ARIMAX-NN tidak lebih baik dari pada ARIMAX.

Langkah selanjutnya adalah menghitung nilai RMSE adaptif untuk 1 hingga 12 bulan kedepan pada data *outflow* dan *inflow* uang kartal pada Tabel 4.82 dan 4.83.


**Tabel 4.82** Hasil Perbandingan RMSE Adaptif *Outflow* Uang Kartal Pada Metode ARIMAX, NN, dan *Hybrid* ARIMAX-NN

t	Nilai Aktual	ARIMAX		NN		Hybrid ARIMAX-NN	
		Ramalan	Adaptif	Ramalan	Adaptif	Ramalan	Adaptif
1	1,287	2,288	1,001	4,022	2,735	2,294	1,007
2	2,573	3,139	0,813	5,030	2,600	3,556	0,995
3	3,143	3,702	0,738	1,710	2,278	3,794	0,895
4	3,315	5,528	1,278	2,894	1,984	5,677	1,413
5	4,207	4,548	1,153	3,134	1,839	5,097	1,325
6	14,051	13,907	1,054	3,339	4,684	13,952	1,210
7	2,985	2,487	0,994	4,135	4,358	2,374	1,144
8	1,662	2,977	1,040	3,682	4,139	2,223	1,088
9	3,826	4,530	1,008	8,746	4,233	4,009	1,028
10	2,754	4,526	1,108	1,018	4,053	3,676	1,018
11	3,495	4,666	1,114	3,536	3,864	4,020	0,983
12	6,107	8,560	1,280	3,816	3,758	8,894	1,238


**Tabel 4.83** Hasil Perbandingan RMSE Adaptif *Inflow* Uang Kartal Pada Metode ARIMAX, NN, dan *Hybrid* ARIMAX-NN

t	Nilai Aktual	ARIMAX		NN		Hybrid ARIMAX-NN	
		Ramalan	Adaptif	Ramalan	Adaptif	Ramalan	Adaptif
1	10,046	9,391	0,654	7,203	2,843	9,027	1,019
2	6,526	6,383	0,474	5,452	2,149	6,237	0,749
3	5,732	8,005	1,368	8,510	2,377	8,203	1,552
4	5,445	6,397	1,277	6,606	2,139	6,558	1,455
5	6,785	6,733	1,142	6,052	1,941	6,865	1,302
6	5,127	6,406	1,166	6,683	1,882	6,486	1,311
7	14,735	19,300	2,035	5,908	3,764	19,386	2,136
8	7,634	8,048	1,909	7,071	3,526	8,138	2,006
9	7,089	7,377	1,803	4,956	3,400	7,476	1,896
10	6,884	9,119	1,851	9,394	3,322	9,217	1,944
11	5,985	8,583	1,931	5,909	3,167	8,680	2,024
12	6,048	5,680	1,851	6,011	3,032	5,776	1,939

Berdasarkan nilai RMSE adaptif pada Tabel 4.82 dan Tabel 4.83, maka dapat disimpulkan bahwa model terbaik untuk meramalkan *outflow* uang kartal untuk 1, 2, 3, 4, 5, 6, 7, 8, dan 9 bulan kedepan adalah ARIMAX, untuk 10, 11, dan 12 bulan kedepan menggunakan *Hybrid* ARIMAX-NN. Pada *inflow* uang kartal, model terbaik untuk meramalkan 1 hingga 12 bulan kedepan adalah ARIMAX. Perbandingan hasil ramalan setiap bulan pada periode Januari hingga Desember 2016 untuk model *outflow* dan *inflow* dapat dilihat pada Gambar 4.44 dan Gambar 4.45.



**Gambar 4.44** Perbandingan Hasil Peramalan *Out-sample* Model ARIMAX, NN, dan *Hybrid* ARIMAX-NN dengan Data *Outflow* Uang Kartal



**Gambar 4.45** Perbandingan Hasil Peramalan *Out-sample* Model ARIMAX, NN, dan *Hybrid* ARIMAX-NN dengan Data *Outflow* Uang Kartal

Berdasarkan model terbaik yang telah didapatkan untuk masing-masing data *inflow* dan *outflow* uang kartal pada Tabel 4.80, maka dilakukan peramalan periode bulan Januari hingga Desember 2017 yang disajikan pada Tabel 4.84. Model Peramalan periode bulan Januari hingga Desember 2017 untuk *outflow* uang kartal adalah sebagai berikut

$$\hat{Z}_{1,t} = \hat{L}_{1,t}^* + \hat{N}_{1,t}, \text{ dengan } \hat{L}_{1,t}^* = \frac{\hat{L}_{1,t}^{0,2} - 1}{0,2}.$$


dimana

$$\begin{aligned} L_{1,t}^* = & -0,006t - 2,733I_{1,t} - 2,208I_{2,t} + 0,026tI_{1,t} + 0,027tI_{2,t} - 0,033M_{1,t} \\ & + 0,290M_{2,t} + 0,589M_{3,t} + 0,816M_{4,t} + 0,690M_{5,t} + 0,953M_{6,t} \\ & + 0,753M_{7,t} + 0,381M_{8,t} + 0,591M_{9,t} + 0,445M_{10,t} + 0,609M_{11,t} \\ & + 1,387M_{12,t} - 0,595D_{1,t} + 1,561D_{2,t} + 1,168D_{3,t} + 1,657D_{4,t} \\ & + 1,791D_{1,t-1} + 1,131D_{2,t-1} + 0,295D_{3,t-1} + 0,450D_{4,t-1} \\ & + \frac{1}{(1 - 0,158B + 0,273B^2 - 0,283B^{13} - 0,229B^{14})(1 - 0,214B^{12})} a_t \end{aligned}$$

$$\hat{N}_{1,t} = 0,245 + 0,347f_1^h - 2,323f_2^h + 1,242f_3^h$$

dengan

$$\begin{aligned} f_1^h &= [1 + \exp(-[0,571 + 0,329a_{t-1} + 4,367a_{t-2} + \dots + 1,306a_{t-26}])]^{-1} \\ f_2^h &= [1 + \exp(-[-0,973 + 0,783a_{t-1} - 0,572a_{t-2} + \dots - 1,753a_{t-26}])]^{-1} \\ f_3^h &= [1 + \exp(-[-0,489 + 1,855a_{t-1} - 2,388a_{t-2} + \dots + 3,853a_{t-26}])]^{-1} \end{aligned}$$



**Gambar 4.46** Arsitektur Model Peramalan *Neural Network* Residual dari Model ARIMAX *Outflow* Uang Kartal

Model Peramalan periode bulan Januari hingga Desember 2017 untuk *inflow* uang kartal adalah sebagai berikut

$$\begin{aligned}
 Z_{2,t}^* = & -1,769I_{1,t} - 0,477I_{2,t} + 0,017I_{1,t} + 0,0091I_{2,t} + 1,423M_{1,t} \\
 & + 1,058M_{2,t} + 1,103M_{3,t} + 0,970M_{4,t} + 0,997M_{5,t} \\
 & + 0,956M_{6,t} + 1,122M_{7,t} + 1,187M_{8,t} + 1,063M_{9,t} \\
 & + 1,201M_{10,t} + 1,124M_{11,t} + 0,781M_{12,t} + 0,813D_{1,t} \\
 & + 0,546D_{2,t} - 0,420D_{4,t} + 0,397D_{2,t+1} + 0,401D_{3,t+1} \\
 & + 0,552D_{4,t+1} + \frac{(1 - 0,222B^{24})}{(1 - 0,314B^3)} a_t
 \end{aligned}$$

**Tabel 4.84** Nilai Ramalan *Inflow* dan *Outflow* Periode Januari-Desember Tahun 2017 (dalam Triliun)

<b>Periode</b>	<b><i>Outflow</i></b>	<b><i>Inflow</i></b>
Januari	2,4653	9,7613
Februari	3,7407	6,9700
Maret	4,6865	8,2768
April	5,3173	6,6670
Mei	7,2045	6,8539
Juni	17,3618	4,4171
Juli	5,8372	13,0035
Agustus	3,9034	9,0657
September	6,2290	8,0482
Oktober	4,4807	9,2813
November	4,7016	8,7296
Desember	9,2704	5,9891

Berdasarkan Tabel 4.84, *outflow* uang kartal di Kantor Perwakilan Bank Indonesia Provinsi Jawa Barat, tertinggi diprediksi akan terjadi pada bulan Juni dan Desember dengan nilai berturut-turut sebesar 17,3618 triliun rupiah dan 9,2704 Triliun rupiah. Hal ini diduga karena pada bulan Juni terjadi hari raya Idul Fitri pada minggu keempat, sehingga menyebabkan *outflow* pada bulan tersebut akan tinggi. Sedangkan pada bulan Desember masyarakat cenderung menggunakan uangnya untuk berlibur akhir tahun. Kemudian pada *inflow* uang kartal di Kantor Perwakilan Bank Indonesia Provinsi Jawa Barat, tertinggi diprediksi akan terjadi pada bulan Juli yaitu sebesar 13,0035 triliun rupiah. Hal ini diduga dikarenakan hari raya Idul Fitri yang jatuh pada minggu keempat bulan Juni, sehingga menyebabkan *inflow* pada bulan setelah hari raya Idul Fitri (Juli) akan tinggi. Sedangkan *inflow* terendah diprediksi terjadi pada bulan Desember yaitu sebesar 5,9891 rupiah, hal ini diduga karena pada masyarakat cenderung menggunakan uangnya untuk berlibur di akhir tahun.

## BAB V

### KESIMPULAN DAN SARAN

#### 5.1 Kesimpulan

Berdasarkan analisis dan pembahasan yang telah dilakukan, maka dapat ditarik kesimpulan sebagai berikut.

1. Berdasarkan hasil studi simulasi skenario 1 hingga 4, metode terbaik untuk menganalisis skenario tersebut adalah *Hybrid ARIMAX-NN*.
2. Karakteristik data *outflow* dan *inflow* uang kartal di Kantor Perwakilan Bank Indonesia Provinsi Jawa Barat dipengaruhi oleh adanya pola musiman yang disebabkan oleh hari raya Idul Fitri dan tahun baru.
3. Model *outflow* uang kartal di Kantor Perwakilan Bank Indonesia Provinsi Jawa Barat menggunakan ARIMAX menghasilkan RMSE *out-sample* sebesar 1,280. Kemudian model *Neural Network* dengan 2 *hidden neuron* menghasilkan nilai RMSE *out-sample* sebesar 3,758 serta model *Hybrid ARIMAX-NN* dengan nilai RMSE *out-sample* sebesar 1,238.
4. Model *inflow* uang kartal di Kantor Perwakilan Bank Indonesia Provinsi Jawa Barat menggunakan ARIMAX menghasilkan nilai RMSE *out-sample* sebesar 1,851. Kemudian model *Neural Network* dengan 1 *hidden neuron* menghasilkan nilai RMSE *out-sample* sebesar 3,032 serta model *Hybrid ARIMAX-NN* dengan nilai RMSE *out-sample* sebesar 1,939.
5. Model yang tepat untuk *outflow* uang kartal di Kantor Perwakilan Bank Indonesia Provinsi Jawa Barat adalah *Hybrid ARIMAX-NN* dengan nilai RMSE *out-sample* sebesar 1,238.
6. Model yang tepat untuk *inflow* uang kartal di Kantor Perwakilan Bank Indonesia Provinsi Jawa Barat adalah ARIMAX dengan nilai RMSE *out-sample* sebesar 1,851.

## 5.2 Saran

Saran untuk penelitian selanjutnya sebaiknya memperhatikan hubungan *outflow* dan *inflow* secara ekonomi serta memasukan faktor-faktor lain yang mempengaruhi *outflow* dan *inflow* uang kartal. Faktor-faktor yang mempengaruhi diantaranya adalah Indeks Harga Konsumen (IHK), inflasi, atau faktor sosial budaya masyarakat setempat. Sehingga diharapkan akurasi peramalan tersebut lebih tinggi.



## DAFTAR PUSTAKA

- Bank Indonesia. (2013). Tentang Bank Indonesia [online]. Retrieved Desember 13, 2016, from <http://www.bi.go.id/id/tentangbi/pesangubernur/Contents/Default.aspx>.
- Bank Indonesia. (2016). *Uang Kartal yang Diedarkan* [online]. Retrieved Desember 15, 2016, from <http://www.bi.go.id/id/statistik/meta-data/SSKI>.
- Bradley, A.A. & Schwartz, S.S. (2011). Summary Verification Measures and Their Interpretation for Ensemble Forecast. *Monthly Weather Review*, 139, 3075-3089.
- Bollerslev, T. (1986). Generalized Autoregressive Conditional Heteroscedasticity. *Journal of Econometrika*, 50, 987-1007.
- Cryer, J.D. & Chan, K.S. (2008). *Time Series Analysis: with Applications in R* (2nd ed.). New York: Springer Science+Business Media, LLC.
- Edward, N. (2011). *Modelling and Forecasting Using Time Series GARCH Models: An Application Of Tanzania Inflation Rate Data*. Disertatation. University of Dares Salaam.
- Enders, W. (2004). *Applied Economics Time Series*. New York: John Wiley & Sons, Inc.
- Engle, R.F. (1982). Autoregressive Conditional Heteroscedasticity with Estimates of The Variance of United Kingdom Inflation, *Econometrica*, 50, 987-1007.
- Febrina, M., Arina, F., dan Ekawati, R. (2013). Peramalan Jumlah Permintaan Produksi Menggunakan Metode Jaringan Syaraf Tiruan Backpropagation. *Jurnal Teknik Industri*, 1 (2), 174-179.

- Hadi, A.F. (2014). *Model Hibrida ARIMAX-NN dan GARCH Untuk Peramalan Outflow dan Inflow Uang Kartal*. Tugas Akhir Statistika-FMIPA Surabaya : Institut Teknologi Sepuluh November.
- Hyndman, R.J. & Koehler, A.B. (2006). Another Look at Measures of Forecast Accuracy. *International Journal of Forecasting*, 679-688.
- Karomah, A. & Suhartono. (2014). Peramalan Netflow Uang Kartal dengan Model Variasi Kalender dan Model Autoregressive Distributed Lag (ARDL). *Jurnal Sains dan Seni ITS*, 3 (2), D103-D108.
- Liu, L.M. (1980). Analysis of Time Series with Calendar Effects. *Manag. Science*, 2, 106-112.
- Makridakis, S. & Hibon, M. (2000). The M3-Competition, Results, Conclusions and Implications. *International Journal of Forecasting*, 16, 451-476.
- Paembonan, M. (2016). *Model ARIMAX, Radial Basis Function Network, dan Hibrida ARIMAX-RBFN untuk Peramalan Outflow dan Inflow Uang Kartal di Papua*. Tesis Statistika-FMIPA Surabaya : Institut Teknologi Sepuluh November.
- Pakaja, F., Naba, A., dan Purwanto. (2012). Peramalan Penjualan Mobil Menggunakan Jaringan Syaraf Tiruan dan Certainty Factor. *Jurnal EECCIS*, 6 (1).
- Pemerintah Jawa Barat. (2011). *Penduduk* [online]. Retrieved Desember 13, 2016, from <http://www.jabarprov.go.id/index.php/pages/id/75>.
- Rachmawati, N.I., Setiawan, dan Suhartono. (2015). Peramalan Inflow dan Outflow Uang Kartal Bank Indonesia di Wilayah Jawa Tengah dengan Menggunakan ARIMA, Time Series Reggression, dan ARIMAX. *Jurnal Sains dan Seni ITS*, 4 (2), 2337-3520.

- Schumacer, R.S. (2011). Ensemble-Based Analysis of Factor Leading to The Development of a Multiday Warm-Season Heavy Rain Event. *Monthly Weather Review*, 139, 3016-3035.
- Siang, J. (2009). *Jaringan Syaraf Tiruan dan Pemogramannya Menggunakan MATLAB*. Yogyakarta: ANDI.
- Terasvirta, T., Lin, C.F., & Granger C.W.J. (1993). Power of The Neural Network Linearity Test. *Journal of Time Series Analysis*, 14, 159-171.
- Thomas, R.G. (1974). *Our Modern Banking and Monetary System*. New York: Prentice Publishing.
- Walpole, R.E. (1995). *Pengantar Statistika*, Edisi ke-3. Alih Bahasa: Bambang Sumantri. Jakarta: Penerbit PT Gramedia Pustaka Utama.
- Wei, W.W.S. (2006). *Time series Analysis Univariate and Multivariate Methods*. New York: Pearson education, Inc.
- Wulansari, R.E. & Suhartono. (2014). Peramalan Netflow Uang Kartal dengan Metode ARIMAX dan Radial Basis Function Network (Studi Kasus Di Bank Indonesia). *Jurnal Sains dan Seni ITS*, 3(2), D73-D7.
- Wulansari, A., Suryanto, E., Ferawati, K., Andalita, I., dan Suhartono. (2014). Penerapan Time Series Regression with Calendar Variation Effect pada Data Netflow Uang Kartal Bank Indonesia Sebagai Solusi Kontrol Likuiditas Perbankan di Indonesia. *Journal Of Theoretical Statistics and Its Applications*, 14 (2), 59-68.
- Xiaojun, S. (2009). *Multivariate GARCH Models for The Greater China Stock Markets*. Tesis, Singapore Management University.

- Yukha, I.F. (2015). *Peramalan Inflow dan Outflow Uang Kartal Bank Indonesia di Wilayah Jawa Barat dengan Menggunakan Hirarki Berdasarkan Variasi Kalender*. Tugas Akhir Statistika-FMIPA Surabaya : Institut Teknologi Sepuluh November.
- Zhang, G.P. (2003). Time Series Forecasting Using a Hybrid ARIMA and Neural Network Model. *Neurocomputing*, 50, 159-175.

**Lampiran 1.** Data *Outflow* dan *Inflow* di Provinsi Jawa Barat  
Periode Januari 2004-Desember 2016

<b>Bulan</b>	<b>Tahun</b>	<b>Outflow</b>	<b>Inflow</b>
Januari	2004	1.336247	3.131145
Februari	2004	1.142117	2.721538
Maret	2004	1.606674	2.996204
April	2004	1.920242	2.850071
Mei	2004	1.413245	2.797858
Juni	2004	2.22573	2.999247
Juli	2004	1.549921	3.118441
Agustus	2004	1.458291	2.925282
September	2004	1.690297	2.886405
Oktober	2004	2.212919	2.878252
November	2004	2.648019	4.387862
Desember	2004	1.957214	3.163633
⋮	⋮	⋮	⋮
Januari	2015	1.791319	9.159041
Februari	2015	2.447945	5.296647
Maret	2015	2.343619	5.875315
April	2015	4.638121	5.619684
Mei	2015	5.103691	5.869826
Juni	2015	5.882918	6.577658
Juli	2015	10.25029	9.821666
Agustus	2015	1.837186	8.974638
September	2015	3.16094	6.232244
Oktober	2015	3.433491	6.697159
November	2015	3.134592	6.108756
Desember	2015	6.303969	5.340208
Januari	2016	1.286991	10.04583
Februari	2016	2.572653	6.526185
Maret	2016	3.143014	5.73236
April	2016	3.315242	5.444531
Mei	2016	4.207036	6.784825
Juni	2016	14.05051	5.126561
Juli	2016	2.984515	14.73515
Agustus	2016	1.662422	7.634414
September	2016	3.825639	7.089318
Oktober	2016	2.75437	6.883659
November	2016	3.495343	5.985418
Desember	2016	6.107095	6.047895

## Lampiran 2. Syntax Program SAS untuk Regresi *Time Series*

```

data outflow;
  input y t I1 I2 tI1 tI2 M1 M2 M3 M4 M5 M6 M7 M8 M9 M10 M11 M12 C1t C2t C3t C4t C1tI C2tI C3tI
  C4tI ;
datalines;
0.298431656 1 0 0 0 0 1 0 0 0 0 0 0 0 0 0 0 0 0 0 0 0 0 0 0
0.134665281 2 0 0 0 0 0 1 0 0 0 0 0 0 0 0 0 0 0 0 0 0 0 0 0
0.497377514 3 0 0 0 0 0 0 1 0 0 0 0 0 0 0 0 0 0 0 0 0 0 0 0
0.696934155 4 0 0 0 0 0 0 0 1 0 0 0 0 0 0 0 0 0 0 0 0 0 0 0
0.358133358 5 0 0 0 0 0 0 0 0 0 1 0 0 0 0 0 0 0 0 0 0 0 0 0
0.867653901 6 0 0 0 0 0 0 0 0 0 0 1 0 0 0 0 0 0 0 0 0 0 0 0
0.457979764 7 0 0 0 0 0 0 0 0 0 0 0 1 0 0 0 0 0 0 0 0 0 0 0
0.391863056 8 0 0 0 0 0 0 0 0 0 0 0 0 1 0 0 0 0 0 0 0 0 0 0
0.553446863 9 0 0 0 0 0 0 0 0 0 0 0 0 0 1 0 0 0 0 0 0 0 0 0
0.860883594 10 0 0 0 0 0 0 0 0 0 0 0 0 0 0 1 0 0 0 0 0 0 0 1
1.075111234 11 0 0 0 0 0 0 0 0 0 0 0 0 0 0 0 1 0 0 0 1 0 0 0
0.718704382 12 0 0 0 0 0 0 0 0 0 0 0 0 0 0 0 0 1 0 0 0 0 0 0
.
.
0.618295413 133 0 1 0 133 1 0 0 0 0 0 0 0 0 0 0 0 0 0 0 0 0 0 0
0.980401315 134 0 1 0 134 0 1 0 0 0 0 0 0 0 0 0 0 0 0 0 0 0 0 0
0.928535435 135 0 1 0 135 0 0 1 0 0 0 0 0 0 0 0 0 0 0 0 0 0 0 0
1.795766002 136 0 1 0 136 0 0 0 1 0 0 0 0 0 0 0 0 0 0 0 0 0 0 0
1.927026992 137 0 1 0 137 0 0 0 0 1 0 0 0 0 0 0 0 0 0 0 0 0 0 0
2.126701298 138 0 1 0 138 0 0 0 0 0 1 0 0 0 0 0 0 0 0 0 0 0 1 0
2.963743098 139 0 1 0 139 0 0 0 0 0 0 1 0 0 0 0 0 0 0 1 0 0 0 0
0.646776608 140 0 1 0 140 0 0 0 0 0 0 0 1 0 0 0 0 0 0 0 0 0 0 0
1.294094341 141 0 1 0 141 0 0 0 0 0 0 0 0 1 0 0 0 0 0 0 0 0 0 0
1.399074808 142 0 1 0 142 0 0 0 0 0 0 0 0 0 1 0 0 0 0 0 0 0 0 0
1.283566377 143 0 1 0 143 0 0 0 0 0 0 0 0 0 0 1 0 0 0 0 0 0 0 0
2.225914382 144 0 1 0 144 0 0 0 0 0 0 0 0 0 0 0 1 0 0 0 0 0 0 0
* 145 0 1 0 145 1 0 0 0 0 0 0 0 0 0 0 0 0 0 0 0 0 0 0 0
* 146 0 1 0 146 0 1 0 0 0 0 0 0 0 0 0 0 0 0 0 0 0 0 0 0
* 147 0 1 0 147 0 0 1 0 0 0 0 0 0 0 0 0 0 0 0 0 0 0 0 0
* 148 0 1 0 148 0 0 0 1 0 0 0 0 0 0 0 0 0 0 0 0 0 0 0 0
* 149 0 1 0 149 0 0 0 0 1 0 0 0 0 0 0 0 0 0 0 0 0 0 0 0
* 150 0 1 0 150 0 0 0 0 0 1 0 0 0 0 0 0 0 0 0 0 1 0 0 0
* 151 0 1 0 151 0 0 0 0 0 0 1 0 0 0 0 0 1 0 0 0 0 0 0 0
* 152 0 1 0 152 0 0 0 0 0 0 0 1 0 0 0 0 0 0 0 0 0 0 0 0
* 153 0 1 0 153 0 0 0 0 0 0 0 0 1 0 0 0 0 0 0 0 0 0 0 0
* 154 0 1 0 154 0 0 0 0 0 0 0 0 0 1 0 0 0 0 0 0 0 0 0 0
* 155 0 1 0 155 0 0 0 0 0 0 0 0 0 0 1 0 0 0 0 0 0 0 0 0
* 156 0 1 0 156 0 0 0 0 0 0 0 0 0 0 0 1 0 0 0 0 0 0 0 0
;

proc arima data = outflow;
  identify var=y crosscorr=(t I1 I2 tI1 tI2 M1 M2 M3 M4 M5 M6 M7 M8 M9 M10 M11 M12 C1t C2t C3t C4t
  C1tI C2tI C3tI C4tI ) nlag=36;
run;
  estimate p=(0) q=(0) input=(t I1 I2 tI1 tI2 M1 M2 M3 M4 M5 M6 M7 M8 M9 M10 M11 M12 C1t C2t C3t
  C4t C1tI C2tI C3tI C4tI) noconstant method=cls;
  forecast out = outflow lead=12 printall;
  outlier maxnum = 10;
run;
proc univariate data=outflow normal;
  var residual;
run;

```

### Lampiran 3. Syntax Program SAS untuk ARIMAX

```

data outflow;
  input y t I1 I2 tI1 tI2 M1 M2 M3 M4 M5 M6 M7 M8 M9 M10 M11 M12 C1t C2t C3t C4t C1t1 C2t1 C3t1
  C4t1 ;
datalines;
0.298431656 1 0 0 0 0 1 0 0 0 0 0 0 0 0 0 0 0 0 0 0 0 0 0 0 0
0.134665281 2 0 0 0 0 0 1 0 0 0 0 0 0 0 0 0 0 0 0 0 0 0 0 0 0
0.497377514 3 0 0 0 0 0 0 1 0 0 0 0 0 0 0 0 0 0 0 0 0 0 0 0 0
0.696934155 4 0 0 0 0 0 0 0 1 0 0 0 0 0 0 0 0 0 0 0 0 0 0 0 0
0.358133358 5 0 0 0 0 0 0 0 0 1 0 0 0 0 0 0 0 0 0 0 0 0 0 0 0
0.867653901 6 0 0 0 0 0 0 0 0 0 1 0 0 0 0 0 0 0 0 0 0 0 0 0 0
0.457979764 7 0 0 0 0 0 0 0 0 0 0 1 0 0 0 0 0 0 0 0 0 0 0 0 0
0.391863056 8 0 0 0 0 0 0 0 0 0 0 0 1 0 0 0 0 0 0 0 0 0 0 0 0
0.553446863 9 0 0 0 0 0 0 0 0 0 0 0 0 1 0 0 0 0 0 0 0 0 0 0 0
0.860883594 10 0 0 0 0 0 0 0 0 0 0 0 0 0 1 0 0 0 0 0 0 0 0 1 0
1.075111234 11 0 0 0 0 0 0 0 0 0 0 0 0 0 0 1 0 0 0 1 0 0 0 0 0
0.718704382 12 0 0 0 0 0 0 0 0 0 0 0 0 0 0 0 1 0 0 0 0 0 0 0 0
.
.
.
0.618295413 133 0 1 0 133 1 0 0 0 0 0 0 0 0 0 0 0 0 0 0 0 0 0 0 0
0.980401315 134 0 1 0 134 0 1 0 0 0 0 0 0 0 0 0 0 0 0 0 0 0 0 0 0
0.928535435 135 0 1 0 135 0 0 1 0 0 0 0 0 0 0 0 0 0 0 0 0 0 0 0 0
1.795766002 136 0 1 0 136 0 0 0 1 0 0 0 0 0 0 0 0 0 0 0 0 0 0 0 0
1.927026992 137 0 1 0 137 0 0 0 0 1 0 0 0 0 0 0 0 0 0 0 0 0 0 0 0
2.126701298 138 0 1 0 138 0 0 0 0 0 1 0 0 0 0 0 0 0 0 0 0 0 0 1 0
2.963743098 139 0 1 0 139 0 0 0 0 0 0 1 0 0 0 0 0 0 0 1 0 0 0 0 0
0.646776608 140 0 1 0 140 0 0 0 0 0 0 0 1 0 0 0 0 0 0 0 0 0 0 0 0
1.294094341 141 0 1 0 141 0 0 0 0 0 0 0 0 1 0 0 0 0 0 0 0 0 0 0 0
1.399074808 142 0 1 0 142 0 0 0 0 0 0 0 0 0 1 0 0 0 0 0 0 0 0 0 0
1.283566377 143 0 1 0 143 0 0 0 0 0 0 0 0 0 0 1 0 0 0 0 0 0 0 0 0
2.225914382 144 0 1 0 144 0 0 0 0 0 0 0 0 0 0 0 1 0 0 0 0 0 0 0 0
* 145 0 1 0 145 1 0 0 0 0 0 0 0 0 0 0 0 0 0 0 0 0 0 0 0 0
* 146 0 1 0 146 0 1 0 0 0 0 0 0 0 0 0 0 0 0 0 0 0 0 0 0 0
* 147 0 1 0 147 0 0 1 0 0 0 0 0 0 0 0 0 0 0 0 0 0 0 0 0 0
* 148 0 1 0 148 0 0 0 1 0 0 0 0 0 0 0 0 0 0 0 0 0 0 0 0 0
* 149 0 1 0 149 0 0 0 0 1 0 0 0 0 0 0 0 0 0 0 0 0 0 0 0 0
* 150 0 1 0 150 0 0 0 0 0 1 0 0 0 0 0 0 0 0 0 1 0 0 0 0
* 151 0 1 0 151 0 0 0 0 0 1 0 0 0 0 0 1 0 0 0 0 0 0 0 0
* 152 0 1 0 152 0 0 0 0 0 0 0 1 0 0 0 0 0 0 0 0 0 0 0 0
* 153 0 1 0 153 0 0 0 0 0 0 0 0 1 0 0 0 0 0 0 0 0 0 0 0
* 154 0 1 0 154 0 0 0 0 0 0 0 0 0 1 0 0 0 0 0 0 0 0 0 0
* 155 0 1 0 155 0 0 0 0 0 0 0 0 0 0 1 0 0 0 0 0 0 0 0 0
* 156 0 1 0 156 0 0 0 0 0 0 0 0 0 0 0 1 0 0 0 0 0 0 0 0
;

proc arima data = outflow;
  identify var=y crosscorr=(t I1 I2 tI1 tI2 M1 M2 M3 M4 M5 M6 M7 M8 M9 M10 M11 M12 C1t C2t C3t C4t
  C1t1 C2t1 C3t1 C4t1 ) nlag=36;
run;
estimate p=(1,2,13,14)(12) q=(0) input=(t I1 I2 tI1 tI2 M1 M2 M3 M4 M5 M6 M7 M8 M9 M10 M11 M12
C1t C2t C3t C4t C1t1 C2t1 C3t1 C4t1) noconstant method=cls;
forecast out = outflow lead=12 printall;
outlier maxnum = 10;
run;
proc univariate data=outflow normal;
var residual;
run;

```

## Lampiran 4. Syntax Program SAS untuk ARIMA

```

data outflow;
input res;
datalines;
0.40022
-0.10694
-0.00899
-0.07286
-0.22694
-0.05607
-0.21324
0.09629
0.08447
0.29790
-0.79448
-0.62945
.
.
.
0.23188
-0.01315
0.07150
-0.46454
0.17043
-0.51830
0.01499
-0.62334
0.01485
0.52111
0.10495
-0.11279
-0.02119
-0.02916
-0.37247
0.20466
0.49396
0.08860
-0.01042
-0.57685
-0.12962
0.09437
-0.19255
-0.15703
.
;
proc arima data=outflow;
identify var=res nlags=36;
estimate p=(1,2,13,14)(12) q=(0) noconstant method=cls;
forecast out=ramalan lead=12;
outlier maxnum=10 ;
proc print data=ramalan;
run;
proc univariate data=ramalan normal;
var residual;
run ;

```



## Lampiran 5. Syntax Program R untuk *Neural Network*

```

set.seed(222)
data=read.csv("E:/Data Real/Outflow Full.txt",sep="," ,header=TRUE)
n=144
l=12
p=14
h=2
Z=data$a[1:n]
a=Z[(p+1):n]
a1=Z[(p):(n-1)]
a2=Z[(p-1):(n-2)]
a3=Z[(p-2):(n-3)]
a5=Z[(p-4):(n-5)]
a7=Z[(p-6):(n-7)]
a11=Z[(p-10):(n-11)]
a12=Z[(p-11):(n-12)]
a13=Z[(p-12):(n-13)]
a14=Z[(p-13):(n-14)]
v=cbind(a,a1,a2,a3,a5,a7,a11,a12,a13,a14)
variables=(v-min(v))/(max(v)-min(v))
net = neuralnet(a~a1+a2+a3+a5+a7+a11+a12+a13+a14, variables, hidden=h, threshold=0.05, stepmax=1000,rep=300,
learningrate.factor=list(minus=0.5,plus=1.2),algorithm="slr",err.fct="sse", act.fct="logistic", linear.output=TRUE):net


k = 66 # neuralnet best repetition
covariate=cbind(a1,a2,a3,a5,a7,a11,a12,a13,a14)
covariate=(covariate-min(v))/(max(v)-min(v))
fits=compute(net, covariate, rep=k)
fits=fits$net.result
fits=(fits)*(max(v)-min(v))+min(v)
rmse.in = sqrt(mean((data$a[(p+1):n]-fits)^2))
forecasts=rep(0,1)
for(i in 1:l)
{
  a1=Z[n-p-1+i]
  a2=Z[n-p-2+i]
  a3=Z[n-p-3+i]
  a5=Z[n-p-5+i]
  a7=Z[n-p-7+i]
  a11=Z[n-p-11+i]
  a12=Z[n-p-12+i]
  a13=Z[n-p-13+i]
  a14=Z[n-p-14+i]
  covariate=cbind(a1,a2,a3,a5,a7,a11,a12,a13,a14)
  covariate=(covariate-min(v))/(max(v)-min(v))
  f=compute(net, covariate, rep=k)
  f=f$net.result
  forecasts[i]=(f)*(max(v)-min(v))+min(v)
  Z[n-p+i]=forecasts[i]
}

rmse.out = sqrt(mean((forecasts[1:l]-data$a[(n+1):(n+l)])^2,na.rm=T))
performance=cbind(mse.in,mse.out,rmse.in,rmse.out,mae.in,mae.out,mdae.in,mdae.out,smape.in,smape.out):performance
plot(net,rep=k)






write.table(fits,"E:/Data Real/NN Outflow/net_fits9inputh=2.csv",sep="," ,row.names=F, col.names=F)
write.table(forecasts,"E:/Data Real/NN Outflow/net_forecasts9inputh=2.csv",row.names=F, col.names=F)
write.table(performance,"E:/Data Real/NN Outflow/net_performance9inputh=2.csv",sep="," , row.names=F,col.names=T)

```


Lampiran 6. *Time Series Plot* Skenario 1




Lampiran 7. *Time Series Plot* Skenario 2



Lampiran 8. *Time Series Plot* Skenario 3



Lampiran 9. *Time Series Plot* Skenario 4



Lampiran 10. Pemodelan ARIMAX Skenario 1 Replikasi 1

Conditional Least Squares Estimation							
Parameter	Estimate	Standard Error	t Value	Approx Pr >  t	Lag	Variable	Shift
AR1,1	0.62341	0.06280	9.93	<.0001	1	y	0
NUM1	0.29142	0.0051756	56.31	<.0001	0	t	0
NUM2	8.72129	0.63402	13.76	<.0001	0	M1	0
NUM3	10.89499	0.64408	16.92	<.0001	0	M2	0
NUM4	14.57942	0.64982	22.44	<.0001	0	M3	0
NUM5	23.23838	0.65392	35.54	<.0001	0	M4	0
NUM6	25.53507	0.65739	38.84	<.0001	0	M5	0
NUM7	28.03874	0.66278	42.30	<.0001	0	M6	0
NUM8	30.20508	0.67235	44.92	<.0001	0	M7	0
NUM9	26.21946	0.67456	38.87	<.0001	0	M8	0
NUM10	25.01437	0.67761	36.92	<.0001	0	M9	0
NUM11	23.47159	0.68579	34.23	<.0001	0	M10	0
NUM12	16.72085	0.67816	24.66	<.0001	0	M11	0
NUM13	12.58471	0.66130	19.03	<.0001	0	M12	0
NUM14	5.23316	0.79749	6.56	<.0001	0	C1t	0
NUM15	23.48307	0.68811	34.13	<.0001	0	C2t	0
NUM16	50.62832	0.69243	73.12	<.0001	0	C3t	0
NUM17	69.34166	0.69218	100.18	<.0001	0	C4t	0
NUM18	39.69773	0.79742	49.78	<.0001	0	C1t1	0
NUM19	29.70995	0.68847	43.15	<.0001	0	C2t1	0
NUM20	25.42581	0.69278	36.70	<.0001	0	C3t1	0
NUM21	20.34046	0.69197	29.40	<.0001	0	C4t1	0
Variance Estimate				2.010584			
Std Error Estimate				1.417951			
AIC				657.0693			
SBC				727.3144			
Number of Residuals				180			
* AIC and SBC do not include log determinant.							

Autocorrelation Check of Residuals									
Lag	Square	DF	To ChiSq	Chi-	Pr >	-----Autocorrelations-----			
6	6.27	5	0.2807	-0.010	0.072	-0.150	0.040	0.028	0.062
12	16.11	11	0.1372	0.152	-0.098	-0.059	-0.071	0.092	-0.042
18	22.52	17	0.1655	0.096	-0.035	-0.003	-0.049	0.083	-0.111
24	28.11	23	0.2115	-0.140	-0.046	-0.046	0.037	-0.018	0.042
30	32.74	29	0.2885	-0.114	-0.033	-0.052	0.042	-0.042	0.036
36	35.59	35	0.4404	-0.021	-0.080	0.001	-0.030	-0.034	-0.062

Tests for Normality				
Test	--Statistic--	-----p Value-----		
Shapiro-Wilk	W	0.990371	Pr < W	0.2678
Kolmogorov-Smirnov	D	0.046213	Pr > D	>0.1500
Cramer-von Mises	W-Sq	0.044	Pr > W-Sq	>0.2500
Anderson-Darling	A-Sq	0.3371	Pr > A-Sq	>0.2500

## Lampiran 11. Pemodelan ARIMAX Skenario 1 Replikasi 2

Conditional Least Squares Estimation							
Parameter	Estimate	Standard Error	t Value	Approx Pr >  t	Lag	Variable	Shift
AR1,1	0.72859	0.05652	12.89	<.0001	1	y	0
NUM1	0.29348	0.0070611	41.56	<.0001	0	t	0
NUM2	8.41908	0.79134	10.64	<.0001	0	M1	0
NUM3	10.47064	0.80770	12.96	<.0001	0	M2	0
NUM4	14.41532	0.81873	17.61	<.0001	0	M3	0
NUM5	23.30999	0.82667	28.20	<.0001	0	M4	0
NUM6	25.94208	0.83268	31.15	<.0001	0	M5	0
NUM7	28.39547	0.83916	33.84	<.0001	0	M6	0
NUM8	30.81214	0.84798	36.34	<.0001	0	M7	0
NUM9	26.30602	0.84984	30.95	<.0001	0	M8	0
NUM10	24.54442	0.85079	28.85	<.0001	0	M9	0
NUM11	22.42116	0.85447	26.24	<.0001	0	M10	0
NUM12	16.23976	0.84397	19.24	<.0001	0	M11	0
NUM13	12.32731	0.82418	14.96	<.0001	0	M12	0
NUM14	7.08982	0.79149	8.96	<.0001	0	C1t	0
NUM15	25.29777	0.68193	37.10	<.0001	0	C2t	0
NUM16	49.65920	0.68718	72.26	<.0001	0	C3t	0
NUM17	69.97527	0.68765	101.76	<.0001	0	C4t	0
NUM18	40.96380	0.79132	51.77	<.0001	0	C1t1	0
NUM19	30.40597	0.68197	44.59	<.0001	0	C2t1	0
NUM20	24.67467	0.68712	35.91	<.0001	0	C3t1	0
NUM21	20.05529	0.68751	29.17	<.0001	0	C4t1	0
Variance Estimate				2.127163			
Std Error Estimate				1.45848			
AIC				667.2148			
SBC				737.4598			
Number of Residuals				180			
* AIC and SBC do not include log determinant.							

Autocorrelation Check of Residuals								
Lag	Square	DF	To ChiSq	Chi-	Pr >	-----Autocorrelations-----		
6	6.46	5	0.2644	0.008	0.062	-0.132	0.041	-0.051 0.095
12	13.10	11	0.2866	0.002	0.008	-0.024	0.055	-0.126 -0.121
18	19.32	17	0.3103	0.023	-0.020	0.082	0.150	0.002 -0.031
24	26.05	23	0.2987	0.020	-0.114	-0.002	-0.046	0.008 -0.130
30	30.57	29	0.3859	0.026	-0.036	-0.067	-0.079	0.010 -0.090
36	41.36	35	0.2127	0.109	0.094	0.067	-0.041	0.069 -0.129

Tests for Normality				
Test	--Statistic--	-----p Value-----		
Shapiro-Wilk	W	0.992515	Pr < W	0.4828
Kolmogorov-Smirnov	D	0.041545	Pr > D	>0.1500
Cramer-von Mises	W-Sq	0.042988	Pr > W-Sq	>0.2500
Anderson-Darling	A-Sq	0.303096	Pr > A-Sq	>0.2500

## Lampiran 12. Pemodelan ARIMAX Skenario 1 Replikasi 3

Conditional Least Squares Estimation							
Parameter	Estimate	Standard Error	t Value	Approx Pr >  t	Lag	Variable	Shift
AR1,1	0.66665	0.05989	11.13	<.0001	1	y	0
NUM1	0.30031	0.0054195	55.41	<.0001	0	t	0
NUM2	7.83108	0.64023	12.23	<.0001	0	M1	0
NUM3	9.72582	0.65157	14.93	<.0001	0	M2	0
NUM4	13.98415	0.65865	21.23	<.0001	0	M3	0
NUM5	22.40582	0.66377	33.76	<.0001	0	M4	0
NUM6	24.50798	0.66787	36.70	<.0001	0	M5	0
NUM7	28.17660	0.67331	41.85	<.0001	0	M6	0
NUM8	30.47694	0.68208	44.68	<.0001	0	M7	0
NUM9	27.04426	0.68415	39.53	<.0001	0	M8	0
NUM10	24.81260	0.68639	36.15	<.0001	0	M9	0
NUM11	22.63726	0.69263	32.68	<.0001	0	M10	0
NUM12	15.66927	0.68452	22.89	<.0001	0	M11	0
NUM13	12.07056	0.66780	18.08	<.0001	0	M12	0
NUM14	5.59986	0.74020	7.57	<.0001	0	C1t	0
NUM15	24.41031	0.63851	38.23	<.0001	0	C2t	0
NUM16	48.63118	0.64322	75.61	<.0001	0	C3t	0
NUM17	69.81019	0.64352	108.48	<.0001	0	C4t	0
NUM18	39.27981	0.74018	53.07	<.0001	0	C1t1	0
NUM19	30.56942	0.63884	47.85	<.0001	0	C2t1	0
NUM20	23.83005	0.64356	37.03	<.0001	0	C3t1	0
NUM21	19.73481	0.64364	30.66	<.0001	0	C4t1	0
Variance Estimate				1.779787			
Std Error Estimate				1.334087			
AIC				635.1216			
SBC				705.3667			
Number of Residuals				180			
* AIC and SBC do not include log determinant.							

Autocorrelation Check of Residuals								
Lag	Square	DF	To ChiSq	Chi-	Pr >	-----Autocorrelations-----		
6	2.21	5	0.8201	0.048	-0.049	-0.007	-0.023	0.035
12	5.67	11	0.8941	0.033	-0.045	0.010	-0.094	0.035
18	11.84	17	0.8095	-0.102	0.107	0.073	-0.040	-0.035
24	15.91	23	0.8590	0.123	0.056	0.011	0.025	0.023
30	19.23	29	0.9152	-0.037	0.070	0.047	-0.003	0.084
36	23.11	35	0.9384	-0.105	-0.037	-0.047	-0.030	-0.042

Tests for Normality				
Test	--Statistic--	-----p Value-----		
Shapiro-Wilk	W	0.986734	Pr < W	0.0881
Kolmogorov-Smirnov	D	0.068946	Pr > D	0.0360
Cramer-von Mises	W-Sq	0.070699	Pr > W-Sq	>0.2500
Anderson-Darling	A-Sq	0.416653	Pr > A-Sq	>0.2500



### Lampiran 13. Pemodelan ARIMAX Skenario 1 Replikasi 4

Conditional Least Squares Estimation							
Parameter	Estimate	Standard Error	t Value	Approx Pr >  t	Lag	Variable	Shift
AR1,1	0.75011	0.05293	14.17	<.0001	1	y	0
NUM1	0.30675	0.0077189	39.74	<.0001	0	t	0
NUM2	7.43577	0.85004	8.75	<.0001	0	M1	0
NUM3	10.12786	0.86833	11.66	<.0001	0	M2	0
NUM4	13.88291	0.88098	15.76	<.0001	0	M3	0
NUM5	22.74504	0.89017	25.55	<.0001	0	M4	0
NUM6	24.78001	0.89704	27.62	<.0001	0	M5	0
NUM7	28.17962	0.90388	31.18	<.0001	0	M6	0
NUM8	29.50182	0.91262	32.33	<.0001	0	M7	0
NUM9	24.99433	0.91439	27.33	<.0001	0	M8	0
NUM10	24.04443	0.91442	26.29	<.0001	0	M9	0
NUM11	21.76097	0.91661	23.74	<.0001	0	M10	0
NUM12	15.57716	0.90519	17.21	<.0001	0	M11	0
NUM13	11.82862	0.88453	13.37	<.0001	0	M12	0
NUM14	4.39559	0.80182	5.48	<.0001	0	C1t	0
NUM15	25.07925	0.69044	36.32	<.0001	0	C2t	0
NUM16	50.10687	0.69598	71.99	<.0001	0	C3t	0
NUM17	69.70676	0.69632	100.11	<.0001	0	C4t	0
NUM18	40.10785	0.80180	50.02	<.0001	0	C1t1	0
NUM19	30.22072	0.69049	43.77	<.0001	0	C2t1	0
NUM20	24.50489	0.69595	35.21	<.0001	0	C3t1	0
NUM21	20.72426	0.69619	29.77	<.0001	0	C4t1	0
Variance Estimate				2.216633			
Std Error Estimate				1.488836			
AIC				674.6308			
SBC				744.8759			
Number of Residuals				180			
* AIC and SBC do not include log determinant.							

Autocorrelation Check of Residuals								
Lag	Square	DF	To ChiSq	Chi-	Pr >	-----Autocorrelations-----		
6	0.50	5	0.9922	-0.029	0.007	-0.020	0.029	0.010 -0.021
12	3.58	11	0.9806	0.025	0.077	0.089	-0.034	0.017 0.012
18	4.57	17	0.9987	0.030	0.001	0.032	0.036	0.007 -0.041
24	11.82	23	0.9731	0.008	0.034	0.037	-0.001	0.092 -0.153
30	14.83	29	0.9863	-0.030	0.003	0.008	0.029	-0.026 -0.106
36	23.37	35	0.9334	0.052	0.090	-0.032	-0.022	-0.098 -0.127

Tests for Normality				
Test	--Statistic--	-----p Value-----		
Shapiro-Wilk	W	0.995188	Pr < W	0.8335
Kolmogorov-Smirnov	D	0.042954	Pr > D	>0.1500
Cramer-von Mises	W-Sq	0.03941	Pr > W-Sq	>0.2500
Anderson-Darling	A-Sq	0.24302	Pr > A-Sq	>0.2500

## Lampiran 14. Pemodelan ARIMAX Skenario 1 Replikasi 5

Conditional Least Squares Estimation							
Parameter	Estimate	Standard Error	t Value	Approx Pr >  t	Lag	Variable	Shift
ARI,1	0.70642	0.05743	12.30	<.0001	1	y	0
NUM1	0.29882	0.0072271	41.35	<.0001	0	t	0
NUM2	7.67018	0.82660	9.28	<.0001	0	M1	0
NUM3	9.71585	0.84281	11.53	<.0001	0	M2	0
NUM4	13.53860	0.85342	15.86	<.0001	0	M3	0
NUM5	23.04819	0.86103	26.77	<.0001	0	M4	0
NUM6	25.39975	0.86689	29.30	<.0001	0	M5	0
NUM7	28.26567	0.87382	32.35	<.0001	0	M6	0
NUM8	29.82417	0.88367	33.75	<.0001	0	M7	0
NUM9	26.27447	0.88572	29.66	<.0001	0	M8	0
NUM10	24.38784	0.88735	27.48	<.0001	0	M9	0
NUM11	22.15113	0.89266	24.81	<.0001	0	M10	0
NUM12	15.07411	0.88203	17.09	<.0001	0	M11	0
NUM13	11.42705	0.86118	13.27	<.0001	0	M12	0
NUM14	4.86399	0.87404	5.56	<.0001	0	C1t	0
NUM15	24.47236	0.75833	32.27	<.0001	0	C2t	0
NUM16	50.04801	0.75980	65.87	<.0001	0	C3t	0
NUM17	70.96496	0.75899	93.50	<.0001	0	C4t	0
NUM18	40.86315	0.87395	46.76	<.0001	0	C1t1	0
NUM19	29.36152	0.75979	38.64	<.0001	0	C2t1	0
NUM20	25.00165	0.76020	32.89	<.0001	0	C3t1	0
NUM21	19.51860	0.75880	25.72	<.0001	0	C4t1	0
Variance Estimate				2.55062			
Std Error Estimate				1.597066			
AIC				699.8933			
SBC				770.1384			
Number of Residuals				180			
* AIC and SBC do not include log determinant.							

Autocorrelation Check of Residuals								
Lag	Square	DF	To ChiSq	Chi-----	Pr >-----	Autocorrelations-----		
6	2.31	5	0.8052	-0.016	0.006	-0.057	0.082	0.046
12	4.71	11	0.9442	0.045	-0.097	0.033	-0.010	-0.002
18	7.91	17	0.9684	0.053	-0.010	-0.035	-0.001	-0.109
24	12.95	23	0.9531	-0.098	-0.030	-0.051	0.015	0.077
30	14.82	29	0.9864	0.022	-0.007	0.013	0.035	-0.050
36	19.52	35	0.9840	-0.070	0.028	-0.114	-0.006	0.030

Tests for Normality				
Test	--Statistic--	-----p Value-----		
Shapiro-Wilk	W	0.992261	Pr < W	0.4524
Kolmogorov-Smirnov	D	0.045104	Pr > D	>0.1500
Cramer-von Mises	W-Sq	0.067816	Pr > W-Sq	>0.2500
Anderson-Darling	A-Sq	0.467752	Pr > A-Sq	>0.2500

Lampiran 15. Pemodelan ARIMAX Skenario 2 Replikasi 1

Conditional Least Squares Estimation							
Parameter	Estimate	Standard Error	t Value	Approx Pr >  t	Lag	Variable	Shift
AR1,1	0.37443	0.07437	5.03	<.0001	1	y	0
NUM1	0.29469	0.0072587	40.60	<.0001	0	t	0
NUM2	9.65938	1.07714	8.97	<.0001	0	M1	0
NUM3	9.92150	1.08419	9.15	<.0001	0	M2	0
NUM4	14.89121	1.08805	13.69	<.0001	0	M3	0
NUM5	23.46225	1.09196	21.49	<.0001	0	M4	0
NUM6	25.18583	1.09607	22.98	<.0001	0	M5	0
NUM7	26.73334	1.10818	24.12	<.0001	0	M6	0
NUM8	28.88454	1.13424	25.47	<.0001	0	M7	0
NUM9	25.23973	1.13831	22.17	<.0001	0	M8	0
NUM10	25.23962	1.14830	21.98	<.0001	0	M9	0
NUM11	22.97820	1.17576	19.54	<.0001	0	M10	0
NUM12	16.21042	1.16273	13.94	<.0001	0	M11	0
NUM13	12.58525	1.12812	11.16	<.0001	0	M12	0
NUM14	4.51163	1.88577	2.39	0.0179	0	C1t	0
NUM15	24.62640	1.62675	15.14	<.0001	0	C2t	0
NUM16	52.84752	1.62909	32.44	<.0001	0	C3t	0
NUM17	69.08814	1.63300	42.31	<.0001	0	C4t	0
NUM18	35.96654	1.88896	19.04	<.0001	0	C1t1	0
NUM19	27.26657	1.62739	16.75	<.0001	0	C2t1	0
NUM20	26.93198	1.62969	16.53	<.0001	0	C3t1	0
NUM21	20.32265	1.63351	12.44	<.0001	0	C4t1	0
Variance Estimate				10.10583			
Std Error Estimate				3.178967			
AIC				947.713			
SBC				1017.958			
Number of Residuals				180			
* AIC and SBC do not include log determinant.							

Autocorrelation Check of Residuals									
Lag	Square	DF	To ChiSq	Chi-	Pr >	-----Autocorrelations-----			
6	0.94	5	0.9675	-0.007	0.017	-0.012	0.055	-0.034	-0.019
12	9.32	11	0.5923	0.110	0.038	-0.093	0.087	-0.087	-0.079
18	18.61	17	0.3513	0.043	0.027	0.112	-0.109	-0.113	-0.081
24	29.29	23	0.1707	-0.107	-0.039	0.041	-0.020	-0.031	-0.188
30	41.09	29	0.0677	-0.001	-0.173	0.028	-0.114	-0.069	-0.081
36	44.16	35	0.1379	0.074	0.030	-0.067	-0.045	0.010	-0.028

Tests for Normality				
Test	--Statistic--	-----p Value-----		
Shapiro-Wilk	W	0.991458	Pr < W	0.3649
Kolmogorov-Smirnov	D	0.044368	Pr > D	>0.1500
Cramer-von Mises	W-Sq	0.054891	Pr > W-Sq	>0.2500
Anderson-Darling	A-Sq	0.406662	Pr > A-Sq	>0.2500

## Lampiran 16. Pemodelan ARIMAX Skenario 2 Replikasi 2

Conditional Least Squares Estimation							
Parameter	Estimate	Standard Error	t Value	Approx Pr >  t	Lag	Variable	Shift
AR1,1	0.28620	0.07596	3.77	0.0002	1	y	0
AR1,2	0.35916	0.07707	4.66	<.0001	2	y	0
NUM1	0.29833	0.01133	26.34	<.0001	0	t	0
NUM2	7.91450	1.34165	5.90	<.0001	0	M1	0
NUM3	9.92270	1.35014	7.35	<.0001	0	M2	0
NUM4	13.42556	1.36442	9.84	<.0001	0	M3	0
NUM5	22.43037	1.37224	16.35	<.0001	0	M4	0
NUM6	24.83644	1.38005	18.00	<.0001	0	M5	0
NUM7	28.07488	1.39136	20.18	<.0001	0	M6	0
NUM8	30.62649	1.40737	21.76	<.0001	0	M7	0
NUM9	25.79232	1.41169	18.27	<.0001	0	M8	0
NUM10	23.51747	1.41601	16.61	<.0001	0	M9	0
NUM11	22.37589	1.42820	15.67	<.0001	0	M10	0
NUM12	14.83701	1.41467	10.49	<.0001	0	M11	0
NUM13	11.97523	1.39813	8.57	<.0001	0	M12	0
NUM14	4.65898	1.63919	2.84	0.0051	0	C1t	0
NUM15	28.59329	1.41196	20.25	<.0001	0	C2t	0
NUM16	49.78748	1.42015	35.06	<.0001	0	C3t	0
NUM17	72.29074	1.42417	50.76	<.0001	0	C4t	0
NUM18	39.21367	1.64099	23.90	<.0001	0	C1t1	0
NUM19	32.11927	1.42098	22.60	<.0001	0	C2t1	0
NUM20	28.13155	1.42161	19.79	<.0001	0	C3t1	0
NUM21	20.21717	1.44123	14.03	<.0001	0	C4t1	0
Variance Estimate				9.047633			
Std Error Estimate				3.007928			
AIC				928.6605			
SBC				1002.098			
Number of Residuals				180			
* AIC and SBC do not include log determinant.							

Autocorrelation Check of Residuals									
Lag	Square	DF	To ChiSq	Chi-	Pr >	-----Autocorrelations-----			
6	3.56	4	0.4681	0.026	0.065	-0.027	-0.076	0.024	-0.084
12	5.41	10	0.8624	0.003	-0.015	-0.085	0.023	0.013	-0.039
18	14.82	16	0.5377	-0.013	-0.050	0.029	0.009	-0.208	-0.013
24	23.32	22	0.3839	0.086	0.012	0.105	-0.098	0.075	-0.086
30	24.85	28	0.6358	0.028	0.019	-0.003	-0.005	-0.069	0.034
36	33.43	34	0.4953	-0.088	0.067	-0.075	0.090	0.045	-0.103

Tests for Normality				
Test	--Statistic--	-----p Value-----		
Shapiro-Wilk	W	0.991832	Pr < W	0.4040
Kolmogorov-Smirnov	D	0.04113	Pr > D	>0.1500
Cramer-von Mises	W-Sq	0.061128	Pr > W-Sq	>0.2500
Anderson-Darling	A-Sq	0.446852	Pr > A-Sq	>0.2500

Lampiran 17. Pemodelan ARIMAX Skenario 2 Replikasi 3

Conditional Least Squares Estimation							
Parameter	Estimate	Standard Error	t Value	Approx Pr >  t	Lag	Variable	Shift
AR1,1	0.34328	0.07504	4.57	<.0001	1	y	0
NUM1	0.30090	0.0068198	44.12	<.0001	0	t	0
NUM2	6.59712	1.03612	6.37	<.0001	0	M1	0
NUM3	8.91668	1.04197	8.56	<.0001	0	M2	0
NUM4	13.65024	1.04539	13.06	<.0001	0	M3	0
NUM5	22.56954	1.04900	21.52	<.0001	0	M4	0
NUM6	25.39377	1.05280	24.12	<.0001	0	M5	0
NUM7	26.10388	1.06474	24.52	<.0001	0	M6	0
NUM8	29.05305	1.09069	26.64	<.0001	0	M7	0
NUM9	24.89552	1.09461	22.74	<.0001	0	M8	0
NUM10	23.95679	1.10462	21.69	<.0001	0	M9	0
NUM11	23.38678	1.13185	20.66	<.0001	0	M10	0
NUM12	15.52731	1.11933	13.87	<.0001	0	M11	0
NUM13	12.96464	1.08532	11.95	<.0001	0	M12	0
NUM14	3.78002	1.86187	2.03	0.0440	0	C1t	0
NUM15	24.07685	1.60685	14.98	<.0001	0	C2t	0
NUM16	51.12647	1.60927	31.77	<.0001	0	C3t	0
NUM17	68.60642	1.61132	42.58	<.0001	0	C4t	0
NUM18	38.44799	1.86394	20.63	<.0001	0	C1t1	0
NUM19	32.50373	1.60706	20.23	<.0001	0	C2t1	0
NUM20	26.53445	1.61097	16.47	<.0001	0	C3t1	0
NUM21	19.41653	1.60932	12.07	<.0001	0	C4t1	0
Variance Estimate				9.788337			
Std Error Estimate				3.128632			
AIC				941.9672			
SBC				1012.212			
Number of Residuals				180			
* AIC and SBC do not include log determinant.							

Autocorrelation Check of Residuals									
Lag	Square	DF	To ChiSq	Chi-	Pr > Autocorrelations-----				
6	0.68	5	0.9843	0.005	-0.014	0.015	-0.043	-0.012	0.034
12	2.91	11	0.9918	0.061	-0.040	0.061	-0.004	0.028	-0.043
18	11.49	17	0.8298	0.124	-0.102	-0.055	-0.079	-0.090	-0.008
24	22.65	23	0.4816	0.062	0.127	-0.041	0.081	-0.063	-0.146
30	29.97	29	0.4157	0.021	0.121	-0.092	-0.063	-0.002	-0.082
36	33.61	35	0.5350	-0.021	0.041	0.007	-0.056	-0.008	-0.104

Tests for Normality				
Test	--Statistic--	-----p Value-----		
Shapiro-Wilk	W	0.989824	Pr < W	0.2278
Kolmogorov-Smirnov	D	0.063266	Pr > D	0.0782
Cramer-von Mises	W-Sq	0.098983	Pr > W-Sq	0.1182
Anderson-Darling	A-Sq	0.550576	Pr > A-Sq	0.1589

## Lampiran 18. Pemodelan ARIMAX Skenario 2 Replikasi 4

Conditional Least Squares Estimation							
Parameter	Estimate	Standard Error	t Value	Approx Pr >  t	Lag	Variable	Shift
ARI,1	0.34044	0.07661	4.44	<.0001	1	y	0
NUM1	0.29788	0.0071469	41.68	<.0001	0	t	0
NUM2	7.95654	1.08848	7.31	<.0001	0	M1	0
NUM3	8.63148	1.09432	7.89	<.0001	0	M2	0
NUM4	13.88359	1.09779	12.65	<.0001	0	M3	0
NUM5	21.99822	1.10158	19.97	<.0001	0	M4	0
NUM6	24.60564	1.10558	22.26	<.0001	0	M5	0
NUM7	27.88101	1.11833	24.93	<.0001	0	M6	0
NUM8	30.76118	1.14596	26.84	<.0001	0	M7	0
NUM9	25.96428	1.14983	22.58	<.0001	0	M8	0
NUM10	24.52195	1.16021	21.14	<.0001	0	M9	0
NUM11	21.59959	1.18885	18.17	<.0001	0	M10	0
NUM12	15.46760	1.17545	13.16	<.0001	0	M11	0
NUM13	11.82905	1.13982	10.38	<.0001	0	M12	0
NUM14	5.17308	1.96061	2.64	0.0092	0	C1t	0
NUM15	26.85787	1.69220	15.87	<.0001	0	C2t	0
NUM16	52.21986	1.69382	30.83	<.0001	0	C3t	0
NUM17	68.53758	1.69898	40.34	<.0001	0	C4t	0
NUM18	40.28924	1.96440	20.51	<.0001	0	C1t1	0
NUM19	27.47482	1.69318	16.23	<.0001	0	C2t1	0
NUM20	24.60580	1.69471	14.52	<.0001	0	C3t1	0
NUM21	20.66908	1.70125	12.15	<.0001	0	C4t1	0
Variance Estimate				10.8432			
Std Error Estimate				3.292901			
AIC				960.3896			
SBC				1030.635			
Number of Residuals				180			
* AIC and SBC do not include log determinant.							

Autocorrelation Check of Residuals								
Lag	Square	DF	To ChiSq	Chi-	Pr >	-----Autocorrelations-----		
6	1.23	5	0.9417	-0.011	0.021	0.051	-0.031	-0.050 0.001
12	8.28	11	0.6877	-0.079	0.072	0.017	-0.054	-0.134 -0.065
18	13.94	17	0.6711	0.011	-0.003	0.147	0.063	-0.040 -0.034
24	21.20	23	0.5687	-0.008	-0.162	0.009	0.052	-0.077 0.015
30	26.39	29	0.6045	0.072	-0.091	-0.043	-0.046	0.080 0.022
36	31.62	35	0.6322	0.006	-0.033	0.033	0.074	-0.015 -0.123

Tests for Normality				
Test	--Statistic--	-----p Value-----		
Shapiro-Wilk	W 0.987859	Pr < W	0.1250	
Kolmogorov-Smirnov	D 0.052036	Pr > D	>0.1500	
Cramer-von Mises	W-Sq 0.085452	Pr > W-Sq	0.1812	
Anderson-Darling	A-Sq 0.563477	Pr > A-Sq	0.1465	

Lampiran 19. Pemodelan ARIMAX Skenario 2 Replikasi 5

Conditional Least Squares Estimation							
Parameter	Estimate	Standard Error	t Value	Approx Pr >  t	Lag	Variable	Shift
AR1,1	0.32920	0.07679	4.29	<.0001	1	y	0
NUM1	0.29415	0.0071042	41.40	<.0001	0	t	0
NUM2	7.61809	1.09068	6.98	<.0001	0	M1	0
NUM3	9.43499	1.09634	8.61	<.0001	0	M2	0
NUM4	14.48562	1.09980	13.17	<.0001	0	M3	0
NUM5	23.64314	1.10356	21.42	<.0001	0	M4	0
NUM6	25.44712	1.10751	22.98	<.0001	0	M5	0
NUM7	28.86513	1.12018	25.77	<.0001	0	M6	0
NUM8	30.83356	1.14770	26.87	<.0001	0	M7	0
NUM9	29.41270	1.15180	25.54	<.0001	0	M8	0
NUM10	24.88271	1.16247	21.40	<.0001	0	M9	0
NUM11	22.15942	1.19155	18.60	<.0001	0	M10	0
NUM12	16.81489	1.17823	14.27	<.0001	0	M11	0
NUM13	11.46285	1.14246	10.03	<.0001	0	M12	0
NUM14	5.51912	1.98068	2.79	0.0060	0	C1t	0
NUM15	22.26390	1.71225	13.00	<.0001	0	C2t	0
NUM16	51.59396	1.71400	30.10	<.0001	0	C3t	0
NUM17	68.75917	1.71705	40.05	<.0001	0	C4t	0
NUM18	38.93872	1.98187	19.65	<.0001	0	C1t1	0
NUM19	25.90855	1.71610	15.10	<.0001	0	C2t1	0
NUM20	25.59642	1.71940	14.89	<.0001	0	C3t1	0
NUM21	17.69607	1.71931	10.29	<.0001	0	C4t1	0
Variance Estimate				11.0549			
Std Error Estimate				3.324891			
AIC				963.8701			
SBC				1034.115			
Number of Residuals				180			
* AIC and SBC do not include log determinant.							

Autocorrelation Check of Residuals									
Lag	Square	DF	To ChiSq	Chi-	Pr > Autocorrelations-----				
6	1.83	5	0.8719	0.008	-0.039	0.065	-0.045	-0.005	-0.045
12	13.04	11	0.2904	-0.147	0.075	0.031	-0.160	-0.000	-0.068
18	15.95	17	0.5275	-0.067	-0.061	-0.017	-0.036	0.014	-0.068
24	18.07	23	0.7539	-0.062	0.035	0.044	-0.011	0.056	0.008
30	19.13	29	0.9179	-0.021	0.055	-0.019	-0.027	-0.017	0.010
36	22.27	35	0.9532	-0.041	-0.039	0.021	0.091	-0.036	-0.029

Tests for Normality				
Test	--Statistic--	-----p Value-----		
Shapiro-Wilk	W	0.994996	Pr < W	0.8102
Kolmogorov-Smirnov	D	0.037643	Pr > D	>0.1500
Cramer-von Mises	W-Sq	0.0292	Pr > W-Sq	>0.2500
Anderson-Darling	A-Sq	0.186233	Pr > A-Sq	>0.2500

## Lampiran 20. Pemodelan ARIMAX Skenario 3 Replikasi 1

Conditional Least Squares Estimation								
Parameter	Estimate	Standard Error	t Value	Approx Pr >  t	Lag	Variable	Shift	
AR1,1	0.41736	0.07349	5.68	<.0001	1	y	0	
NUM1	0.29752	0.0078920	37.70	<.0001	0	t	0	
NUM2	8.14510	1.13410	7.18	<.0001	0	M1	0	
NUM3	8.65182	1.14297	7.57	<.0001	0	M2	0	
NUM4	11.66626	1.14761	10.17	<.0001	0	M3	0	
NUM5	12.27419	1.15201	10.65	<.0001	0	M4	0	
NUM6	17.26359	1.15657	14.93	<.0001	0	M5	0	
NUM7	18.62315	1.16865	15.94	<.0001	0	M6	0	
NUM8	21.36732	1.19468	17.89	<.0001	0	M7	0	
NUM9	18.38658	1.19934	15.33	<.0001	0	M8	0	
NUM10	19.02887	1.20914	15.74	<.0001	0	M9	0	
NUM11	18.91910	1.23663	15.30	<.0001	0	M10	0	
NUM12	9.93878	1.22296	8.13	<.0001	0	M11	0	
NUM13	8.12372	1.18746	6.84	<.0001	0	M12	0	
NUM14	14.56281	1.90612	7.64	<.0001	0	C1t	0	
NUM15	27.20862	1.64765	16.51	<.0001	0	C2t	0	
NUM16	46.81589	1.65418	28.30	<.0001	0	C3t	0	
NUM17	70.13490	1.65097	42.48	<.0001	0	C4t	0	
NUM18	43.09861	1.90734	22.60	<.0001	0	C1t1	0	
NUM19	27.86348	1.65169	16.87	<.0001	0	C2t1	0	
NUM20	23.42867	1.66113	14.10	<.0001	0	C3t1	0	
NUM21	17.26807	1.65036	10.46	<.0001	0	C4t1	0	
Variance Estimate				10.45633				
Std Error Estimate				3.233625				
AIC				953.8502				
SBC				1024.095				
Number of Residuals				180				
* AIC and SBC do not include log determinant.								

Autocorrelation Check of Residuals									
Lag	Square	DF	To ChiSq	Chi-	Pr >	-----Autocorrelations-----			
6	6.91	5	0.2275	-0.034	0.046	0.119	-0.082	0.024	-0.112
12	14.54	11	0.2046	0.088	0.064	-0.026	0.070	0.114	-0.097
18	18.31	17	0.3696	-0.064	0.098	0.068	0.007	0.011	0.026
24	27.36	23	0.2410	0.096	-0.168	-0.047	-0.006	0.024	0.061
30	38.49	29	0.1118	-0.013	0.165	0.088	-0.012	0.077	0.103
36	47.51	35	0.0771	-0.076	-0.151	0.029	-0.045	-0.078	-0.056

Tests for Normality				
Test	--Statistic--	-----p Value-----		
Shapiro-Wilk	W	0.988784	Pr < W	0.1664
Kolmogorov-Smirnov	D	0.041339	Pr > D	>0.1500
Cramer-von Mises	W-Sq	0.03762	Pr > W-Sq	>0.2500
Anderson-Darling	A-Sq	0.282913	Pr > A-Sq	>0.2500



## Lampiran 21. Pemodelan ARIMAX Skenario 3 Replikasi 2

Conditional Least Squares Estimation							
Parameter	Estimate	Standard Error	t Value	Approx Pr >  t	Lag	Variable	Shift
AR1,1	0.34106	0.07595	4.49	<.0001	1	y	0
NUM1	0.31220	0.0073117	42.70	<.0001	0	t	0
NUM2	7.50162	1.11261	6.74	<.0001	0	M1	0
NUM3	6.84178	1.11886	6.11	<.0001	0	M2	0
NUM4	10.92464	1.12253	9.73	<.0001	0	M3	0
NUM5	11.08322	1.12641	9.84	<.0001	0	M4	0
NUM6	15.99029	1.13048	14.14	<.0001	0	M5	0
NUM7	18.11526	1.14320	15.85	<.0001	0	M6	0
NUM8	19.92582	1.17106	17.02	<.0001	0	M7	0
NUM9	17.08806	1.17533	14.54	<.0001	0	M8	0
NUM10	19.11771	1.18610	16.12	<.0001	0	M9	0
NUM11	18.84467	1.21574	15.50	<.0001	0	M10	0
NUM12	8.87630	1.20194	7.38	<.0001	0	M11	0
NUM13	7.55803	1.16545	6.49	<.0001	0	M12	0
NUM14	15.30115	2.00546	7.63	<.0001	0	C1t	0
NUM15	24.86621	1.72939	14.38	<.0001	0	C2t	0
NUM16	48.02872	1.73519	27.68	<.0001	0	C3t	0
NUM17	72.00551	1.73385	41.53	<.0001	0	C4t	0
NUM18	43.38483	2.01195	21.56	<.0001	0	C1t1	0
NUM19	25.12672	1.73086	14.52	<.0001	0	C2t1	0
NUM20	23.81930	1.74377	13.66	<.0001	0	C3t1	0
NUM21	17.27100	1.73267	9.97	<.0001	0	C4t1	0
Variance Estimate				11.32405			
Std Error Estimate				3.365122			
AIC				968.1999			
SBC				1038.445			
Number of Residuals				180			
* AIC and SBC do not include log determinant.							

Autocorrelation Check of Residuals								
Lag	Square	DF	To ChiSq	Chi-	Pr >	-----Autocorrelations-----		
6	6.59	5	0.2532	-0.007	-0.035	0.145	0.020	0.112 -0.015
12	12.42	11	0.3331	0.088	-0.064	-0.050	0.064	0.086 -0.067
18	14.94	17	0.5997	-0.092	0.042	0.021	-0.010	-0.045 -0.005
24	18.96	23	0.7038	0.079	-0.065	-0.002	-0.029	-0.036 -0.083
30	24.43	29	0.7073	-0.088	0.093	0.077	0.002	-0.057 0.003
36	42.38	35	0.1827	-0.062	-0.219	0.059	-0.029	-0.129 -0.089

Tests for Normality				
Test	--Statistic--	-----p Value-----		
Shapiro-Wilk	W	0.993489	Pr < W	0.6086
Kolmogorov-Smirnov	D	0.033741	Pr > D	>0.1500
Cramer-von Mises	W-Sq	0.03871	Pr > W-Sq	>0.2500
Anderson-Darling	A-Sq	0.289783	Pr > A-Sq	>0.2500

## Lampiran 22. Pemodelan ARIMAX Skenario 3 Replikasi 3

Conditional Least Squares Estimation							
Parameter	Estimate	Standard Error	t Value	Approx Pr >  t	Lag	Variable	Shift
ARI,1	0.49980	0.07081	7.06	<.0001	1	y	0
NUM1	0.29212	0.0098309	29.71	<.0001	0	t	0
NUM2	8.95482	1.32694	6.75	<.0001	0	M1	0
NUM3	8.38332	1.34109	6.25	<.0001	0	M2	0
NUM4	11.86943	1.34826	8.80	<.0001	0	M3	0
NUM5	12.43267	1.35423	9.18	<.0001	0	M4	0
NUM6	18.10314	1.36016	13.31	<.0001	0	M5	0
NUM7	18.89940	1.37350	13.76	<.0001	0	M6	0
NUM8	22.05156	1.40087	15.74	<.0001	0	M7	0
NUM9	19.63350	1.40620	13.96	<.0001	0	M8	0
NUM10	20.85792	1.41570	14.73	<.0001	0	M9	0
NUM11	20.90402	1.44274	14.49	<.0001	0	M10	0
NUM12	11.46074	1.42723	8.03	<.0001	0	M11	0
NUM13	9.43777	1.38787	6.80	<.0001	0	M12	0
NUM14	14.71325	2.02774	7.26	<.0001	0	C1t	0
NUM15	25.37374	1.74818	14.51	<.0001	0	C2t	0
NUM16	47.42098	1.76943	26.80	<.0001	0	C3t	0
NUM17	71.18691	1.75849	40.48	<.0001	0	C4t	0
NUM18	41.55158	2.02849	20.48	<.0001	0	C1t1	0
NUM19	24.94373	1.74837	14.27	<.0001	0	C2t1	0
NUM20	24.36808	1.77966	13.69	<.0001	0	C3t1	0
NUM21	18.28584	1.75786	10.40	<.0001	0	C4t1	0
Variance Estimate				12.1943			
Std Error Estimate				3.492033			
AIC				981.527			
SBC				1051.772			
Number of Residuals				180			
* AIC and SBC do not include log determinant.							

Autocorrelation Check of Residuals								
Lag	Square	DF	To ChiSq	Chi-	Pr >	-----Autocorrelations-----		
6	5.27	5	0.3835	-0.037	0.018	0.138	-0.063	0.032 -0.051
12	9.04	11	0.6181	0.084	0.002	0.003	0.022	0.030 -0.106
18	17.75	17	0.4046	-0.178	0.059	-0.035	-0.023	0.042 -0.073
24	22.90	23	0.4668	0.047	-0.139	-0.013	-0.056	0.009 -0.004
30	28.77	29	0.4769	-0.097	0.092	0.009	-0.058	-0.046 0.064
36	40.25	35	0.2491	0.011	-0.183	0.099	0.022	-0.060 -0.064

Tests for Normality				
Test	--Statistic--	-----p Value-----		
Shapiro-Wilk	W	0.990041	Pr < W	0.2430
Kolmogorov-Smirnov	D	0.039782	Pr > D	>0.1500
Cramer-von Mises	W-Sq	0.052894	Pr > W-Sq	>0.2500
Anderson-Darling	A-Sq	0.433417	Pr > A-Sq	>0.2500

Lampiran 23. Pemodelan ARIMAX Skenario 3 Replikasi 4

Conditional Least Squares Estimation							
Parameter	Estimate	Standard Error	t Value	Approx Pr >  t	Lag	Variable	Shift
AR1,1	0.43761	0.07317	5.98	<.0001	1	y	0
NUM1	0.28769	0.0083657	34.39	<.0001	0	t	0
NUM2	11.55582	1.18276	9.77	<.0001	0	M1	0
NUM3	11.56564	1.19280	9.70	<.0001	0	M2	0
NUM4	15.15569	1.19807	12.65	<.0001	0	M3	0
NUM5	15.60201	1.20290	12.97	<.0001	0	M4	0
NUM6	20.19480	1.20784	16.72	<.0001	0	M5	0
NUM7	21.03763	1.22026	17.24	<.0001	0	M6	0
NUM8	24.09221	1.24681	19.32	<.0001	0	M7	0
NUM9	21.97278	1.25146	17.56	<.0001	0	M8	0
NUM10	23.97179	1.26247	18.99	<.0001	0	M9	0
NUM11	24.43791	1.29131	18.92	<.0001	0	M10	0
NUM12	14.64767	1.27591	11.48	<.0001	0	M11	0
NUM13	12.66515	1.23881	10.22	<.0001	0	M12	0
NUM14	14.53606	1.94840	7.46	<.0001	0	C1t	0
NUM15	27.25828	1.67912	16.23	<.0001	0	C2t	0
NUM16	47.23907	1.68741	28.00	<.0001	0	C3t	0
NUM17	70.83415	1.68774	41.97	<.0001	0	C4t	0
NUM18	41.49297	1.95135	21.26	<.0001	0	C1t1	0
NUM19	25.43904	1.68014	15.14	<.0001	0	C2t1	0
NUM20	24.11182	1.69266	14.24	<.0001	0	C3t1	0
NUM21	18.22042	1.68881	10.79	<.0001	0	C4t1	0
Variance Estimate				10.96871			
Std Error Estimate				3.311904			
AIC				962.4611			
SBC				1032.706			
Number of Residuals				180			
* AIC and SBC do not include log determinant.							

Autocorrelation Check of Residuals								
Lag	Square	DF	To ChiSq	Chi-	Pr >	-----Autocorrelations-----		
6	6.19	5	0.2885	-0.026	-0.000	0.138	-0.045	0.088
12	13.58	11	0.2573	0.156	0.011	-0.024	0.077	0.021
18	16.51	17	0.4880	-0.060	0.089	0.023	-0.021	-0.040
24	23.93	23	0.4079	0.143	-0.031	0.019	-0.071	0.011
30	31.33	29	0.3500	-0.151	0.107	-0.008	-0.000	-0.005
36	44.43	35	0.1319	-0.091	-0.185	0.083	0.058	-0.061

Tests for Normality				
Test	--Statistic--	-----p Value-----		
Shapiro-Wilk	W	0.989232	Pr < W	0.1907
Kolmogorov-Smirnov	D	0.059602	Pr > D	0.1184
Cramer-von Mises	W-Sq	0.103018	Pr > W-Sq	0.1027
Anderson-Darling	A-Sq	0.599315	Pr > A-Sq	0.1208

## Lampiran 24. Pemodelan ARIMAX Skenario 3 Replikasi 5

Conditional Least Squares Estimation							
Parameter	Estimate	Standard Error	t Value	Approx Pr >  t	Lag	Variable	Shift
AR1,1	0.39222	0.07463	5.26	<.0001	1	y	0
NUM1	0.30380	0.0074334	40.87	<.0001	0	t	0
NUM2	9.41745	1.08884	8.65	<.0001	0	M1	0
NUM3	9.78749	1.09649	8.93	<.0001	0	M2	0
NUM4	13.86069	1.10057	12.59	<.0001	0	M3	0
NUM5	14.71536	1.10460	13.32	<.0001	0	M4	0
NUM6	19.64441	1.10883	17.72	<.0001	0	M5	0
NUM7	19.87084	1.12080	17.73	<.0001	0	M6	0
NUM8	22.72891	1.14689	19.82	<.0001	0	M7	0
NUM9	19.84148	1.15117	17.24	<.0001	0	M8	0
NUM10	21.00920	1.16074	18.10	<.0001	0	M9	0
NUM11	20.95389	1.18805	17.64	<.0001	0	M10	0
NUM12	12.01071	1.17482	10.22	<.0001	0	M11	0
NUM13	10.19660	1.14015	8.94	<.0001	0	M12	0
NUM14	14.04898	1.87693	7.49	<.0001	0	C1t	0
NUM15	26.70157	1.61797	16.50	<.0001	0	C2t	0
NUM16	46.79521	1.63117	28.69	<.0001	0	C3t	0
NUM17	71.21439	1.62354	43.86	<.0001	0	C4t	0
NUM18	42.78970	1.88093	22.75	<.0001	0	C1t1	0
NUM19	25.56565	1.61847	15.80	<.0001	0	C2t1	0
NUM20	23.70655	1.64449	14.42	<.0001	0	C3t1	0
NUM21	17.80337	1.62184	10.98	<.0001	0	C4t1	0
Variance Estimate				10.04713			
Std Error Estimate				3.169721			
AIC				946.6644			
SBC				1016.909			
Number of Residuals				180			
* AIC and SBC do not include log determinant.							

Autocorrelation Check of Residuals									
Lag	Square	DF	To ChiSq	Chi-	Pr >	-----Autocorrelations-----			
6	7.73	5	0.1719	-0.039	0.025	0.180	0.017	0.022	-0.079
12	12.71	11	0.3124	0.100	-0.028	-0.059	0.036	0.018	-0.101
18	20.39	17	0.2550	-0.102	0.147	0.059	0.008	-0.045	0.036
24	27.52	23	0.2343	0.164	-0.053	0.016	0.002	0.023	-0.066
30	30.83	29	0.3733	-0.084	0.014	-0.058	-0.053	-0.000	0.046
36	48.06	35	0.0697	0.001	-0.186	0.077	0.009	-0.122	-0.146

Tests for Normality				
Test	--Statistic--	-----p Value-----		
Shapiro-Wilk	W	0.987339	Pr < W	0.1064
Kolmogorov-Smirnov	D	0.05625	Pr > D	>0.1500
Cramer-von Mises	W-Sq	0.109328	Pr > W-Sq	0.0872
Anderson-Darling	A-Sq	0.710406	Pr > A-Sq	0.0659

Lampiran 25. Pemodelan ARIMAX Skenario 4 Replikasi 1

Conditional Least Squares Estimation							
Parameter	Estimate	Standard Error	t Value	Approx Pr >  t	Lag	Variable	Shift
AR1,1	0.29784	0.07688	3.87	0.0002	1	y	0
NUM1	0.29433	0.0079789	36.89	<.0001	0	t	0
NUM2	10.19514	1.25386	8.13	<.0001	0	M1	0
NUM3	8.29671	1.25956	6.59	<.0001	0	M2	0
NUM4	12.68257	1.26334	10.04	<.0001	0	M3	0
NUM5	12.74068	1.26747	10.05	<.0001	0	M4	0
NUM6	17.90332	1.27182	14.08	<.0001	0	M5	0
NUM7	17.27942	1.28666	13.43	<.0001	0	M6	0
NUM8	20.10445	1.31918	15.24	<.0001	0	M7	0
NUM9	18.12933	1.32383	13.69	<.0001	0	M8	0
NUM10	21.58418	1.33645	16.15	<.0001	0	M9	0
NUM11	21.23427	1.37053	15.49	<.0001	0	M10	0
NUM12	10.96427	1.35514	8.09	<.0001	0	M11	0
NUM13	9.44035	1.31342	7.19	<.0001	0	M12	0
NUM14	14.17557	2.33053	6.08	<.0001	0	C1t	0
NUM15	25.47092	2.01414	12.65	<.0001	0	C2t	0
NUM16	50.09338	2.01700	24.84	<.0001	0	C3t	0
NUM17	70.41186	2.01745	34.90	<.0001	0	C4t	0
NUM18	38.11722	2.33322	16.34	<.0001	0	C1t1	0
NUM19	23.30389	2.01767	11.55	<.0001	0	C2t1	0
NUM20	25.89836	2.02620	12.78	<.0001	0	C3t1	0
NUM21	17.98170	2.01673	8.92	<.0001	0	C4t1	0
Variance Estimate				15.21343			
Std Error Estimate				3.90044			
AIC				1021.345			
SBC				1091.59			
Number of Residuals				180			
* AIC and SBC do not include log determinant.							

Autocorrelation Check of Residuals									
Lag	Square	DF	To ChiSq	Chi-	Pr >	-----Autocorrelations-----			
6	3.96	5	0.5554	-0.023	0.079	0.010	-0.092	0.066	-0.039
12	5.49	11	0.9054	0.056	0.041	-0.009	0.018	-0.050	0.015
18	15.45	17	0.5631	-0.100	-0.013	0.124	-0.037	0.024	-0.150
24	22.59	23	0.4850	0.017	-0.114	0.025	-0.044	-0.041	-0.130
30	25.61	29	0.6462	-0.080	0.020	0.008	-0.082	-0.021	-0.015
36	28.35	35	0.7793	0.039	-0.083	0.014	-0.050	-0.035	-0.006

Tests for Normality				
Test	--Statistic--	-----p Value-----		
Shapiro-Wilk	W	0.996227	Pr < W	0.9363
Kolmogorov-Smirnov	D	0.033878	Pr > D	>0.1500
Cramer-von Mises	W-Sq	0.026038	Pr > W-Sq	>0.2500
Anderson-Darling	A-Sq	0.172919	Pr > A-Sq	>0.2500

## Lampiran 26. Pemodelan ARIMAX Skenario 4 Replikasi 2

Conditional Least Squares Estimation							
Parameter	Estimate	Standard Error	t Value	Approx Pr >  t	Lag	Variable	Shift
ARI,1	0.21951	0.07957	2.76	0.0065	1	y	0
NUM1	0.28909	0.0075375	38.35	<.0001	0	t	0
NUM2	9.47042	1.25612	7.54	<.0001	0	M1	0
NUM3	9.69961	1.25992	7.70	<.0001	0	M2	0
NUM4	13.50661	1.26332	10.69	<.0001	0	M3	0
NUM5	12.80190	1.26711	10.10	<.0001	0	M4	0
NUM6	18.65061	1.27104	14.67	<.0001	0	M5	0
NUM7	18.61691	1.28728	14.46	<.0001	0	M6	0
NUM8	23.54759	1.32227	17.81	<.0001	0	M7	0
NUM9	20.41941	1.32586	15.40	<.0001	0	M8	0
NUM10	20.77434	1.33904	15.51	<.0001	0	M9	0
NUM11	23.04007	1.37352	16.77	<.0001	0	M10	0
NUM12	13.14214	1.35847	9.67	<.0001	0	M11	0
NUM13	10.34238	1.31561	7.86	<.0001	0	M12	0
NUM14	12.17755	2.44914	4.97	<.0001	0	C1t	0
NUM15	24.95329	2.11786	11.78	<.0001	0	C2t	0
NUM16	46.35696	2.12156	21.85	<.0001	0	C3t	0
NUM17	68.11444	2.12445	32.06	<.0001	0	C4t	0
NUM18	41.95892	2.45307	17.10	<.0001	0	C1t1	0
NUM19	26.76937	2.11942	12.63	<.0001	0	C2t1	0
NUM20	21.79543	2.14627	10.16	<.0001	0	C3t1	0
NUM21	15.97674	2.13597	7.48	<.0001	0	C4t1	0
Variance Estimate				16.63915			
Std Error Estimate				4.079111			
AIC				1037.469			
SBC				1107.714			
Number of Residuals				180			
* AIC and SBC do not include log determinant.							

Autocorrelation Check of Residuals								
Lag	Square	DF	To ChiSq	Chi-	Pr >	-----Autocorrelations-----		
6	4.55	5	0.4738	0.004	-0.046	0.112	0.060	-0.018 -0.077
12	9.59	11	0.5673	0.111	-0.044	0.002	0.055	0.006 -0.094
18	20.26	17	0.2610	-0.014	0.130	-0.034	0.021	-0.127 0.136
24	28.58	23	0.1947	-0.046	-0.111	-0.029	-0.052	0.114 -0.096
30	32.99	29	0.2783	-0.097	0.078	0.046	-0.042	-0.019 0.030
36	35.08	35	0.4644	-0.043	-0.057	0.035	0.047	-0.029 -0.009

Tests for Normality				
Test	--Statistic--	-----p Value-----		
Shapiro-Wilk	W	0.992969	Pr < W	0.5398
Kolmogorov-Smirnov	D	0.048023	Pr > D	>0.1500
Cramer-von Mises	W-Sq	0.046059	Pr > W-Sq	>0.2500
Anderson-Darling	A-Sq	0.312953	Pr > A-Sq	>0.2500

## Lampiran 27. Pemodelan ARIMAX Skenario 4 Replikasi 3

Conditional Least Squares Estimation							
Parameter	Estimate	Standard Error	t Value	Approx Pr >  t	Lag	Variable	Shift
AR1,1	0.23494	0.07867	2.99	0.0033	1	y	0
NUM1	0.30403	0.0086067	35.32	<.0001	0	t	0
NUM2	8.97944	1.41758	6.33	<.0001	0	M1	0
NUM3	6.71046	1.42228	4.72	<.0001	0	M2	0
NUM4	11.47987	1.42623	8.05	<.0001	0	M3	0
NUM5	11.70335	1.43062	8.18	<.0001	0	M4	0
NUM6	17.53297	1.43516	12.22	<.0001	0	M5	0
NUM7	18.95973	1.45273	13.05	<.0001	0	M6	0
NUM8	21.40965	1.49085	14.36	<.0001	0	M7	0
NUM9	18.12365	1.49571	12.12	<.0001	0	M8	0
NUM10	17.80500	1.51135	11.78	<.0001	0	M9	0
NUM11	19.57949	1.55096	12.62	<.0001	0	M10	0
NUM12	9.64282	1.53322	6.29	<.0001	0	M11	0
NUM13	9.70795	1.48499	6.54	<.0001	0	M12	0
NUM14	15.86462	2.74374	5.78	<.0001	0	C1t	0
NUM15	28.28388	2.36926	11.94	<.0001	0	C2t	0
NUM16	46.82426	2.37050	19.75	<.0001	0	C3t	0
NUM17	70.90280	2.37327	29.88	<.0001	0	C4t	0
NUM18	44.57443	2.75626	16.17	<.0001	0	C1t1	0
NUM19	27.55080	2.37039	11.62	<.0001	0	C2t1	0
NUM20	25.46353	2.38400	10.68	<.0001	0	C3t1	0
NUM21	19.16749	2.37421	8.07	<.0001	0	C4t1	0
Variance Estimate				20.8739			
Std Error Estimate				4.568796			
AIC				1078.283			
SBC				1148.528			
Number of Residuals				180			
* AIC and SBC do not include log determinant.							

Autocorrelation Check of Residuals									
Lag	Square	DF	To ChiSq	Chi-	Pr >	-----Autocorrelations-----			
6	4.14	5	0.5293	-0.012	0.018	0.139	0.046	0.002	-0.021
12	7.73	11	0.7375	-0.028	-0.001	0.076	-0.025	0.047	-0.096
18	11.27	17	0.8424	-0.064	0.029	0.025	-0.092	-0.060	-0.012
24	18.79	23	0.7136	0.077	-0.045	-0.133	-0.039	-0.042	-0.086
30	23.13	29	0.7703	-0.124	0.010	-0.014	-0.057	0.017	0.036
36	36.39	35	0.4036	0.049	-0.107	0.043	0.017	-0.129	-0.161

Tests for Normality				
Test	--Statistic--	-----p Value-----		
Shapiro-Wilk	W	0.992457	Pr < W	0.4757
Kolmogorov-Smirnov	D	0.048299	Pr > D	>0.1500
Cramer-von Mises	W-Sq	0.055394	Pr > W-Sq	>0.2500
Anderson-Darling	A-Sq	0.321485	Pr > A-Sq	>0.2500

## Lampiran 28. Pemodelan ARIMAX Skenario 4 Replikasi 4

Conditional Least Squares Estimation							
Parameter	Estimate	Standard Error	t Value	Approx Pr >  t	Lag	Variable	Shift
AR1,1	0.30715	0.08009	3.84	0.0002	1	y	0
NUM1	0.30418	0.0084681	35.92	<.0001	0	t	0
NUM2	7.19040	1.32243	5.44	<.0001	0	M1	0
NUM3	7.18073	1.32833	5.41	<.0001	0	M2	0
NUM4	11.65916	1.33218	8.75	<.0001	0	M3	0
NUM5	10.86022	1.33653	8.13	<.0001	0	M4	0
NUM6	16.22903	1.34116	12.10	<.0001	0	M5	0
NUM7	17.44866	1.35722	12.86	<.0001	0	M6	0
NUM8	20.15592	1.39159	14.48	<.0001	0	M7	0
NUM9	19.94495	1.39616	14.29	<.0001	0	M8	0
NUM10	19.40205	1.40910	13.77	<.0001	0	M9	0
NUM11	21.58546	1.44548	14.93	<.0001	0	M10	0
NUM12	10.87984	1.42851	7.62	<.0001	0	M11	0
NUM13	7.84777	1.38458	5.67	<.0001	0	M12	0
NUM14	10.35462	2.45023	4.23	<.0001	0	C1t	0
NUM15	25.23802	2.10951	11.96	<.0001	0	C2t	0
NUM16	47.31476	2.12650	22.25	<.0001	0	C3t	0
NUM17	68.09327	2.11269	32.23	<.0001	0	C4t	0
NUM18	41.72551	2.47495	16.86	<.0001	0	C1t1	0
NUM19	26.76205	2.11323	12.66	<.0001	0	C2t1	0
NUM20	21.93565	2.16647	10.13	<.0001	0	C3t1	0
NUM21	15.93544	2.11010	7.55	<.0001	0	C4t1	0
Variance Estimate				16.7142			
Std Error Estimate				4.0883			
AIC				1038.279			
SBC				1108.524			
Number of Residuals				180			
* AIC and SBC do not include log determinant.							

Autocorrelation Check of Residuals								
Lag	Square	DF	To ChiSq	Chi-	Pr >	-----Autocorrelations-----		
6	0.87	5	0.9727	-0.014	0.049	-0.016	0.010	0.040 -0.008
12	7.90	11	0.7220	-0.050	0.019	0.095	0.015	0.062 -0.143
18	14.69	17	0.6179	-0.035	-0.025	0.069	-0.166	-0.005 -0.002
24	18.26	23	0.7431	0.059	-0.058	0.068	-0.049	0.019 -0.056
30	27.72	29	0.5329	-0.124	0.051	0.034	0.018	0.021 0.156
36	31.83	35	0.6220	-0.075	-0.070	-0.070	-0.018	-0.004 -0.052

Tests for Normality				
Test	--Statistic--	-----p Value-----		
Shapiro-Wilk	W 0.994639	Pr < W	0.7644	
Kolmogorov-Smirnov	D 0.052266	Pr > D	>0.1500	
Cramer-von Mises	W-Sq 0.042076	Pr > W-Sq	>0.2500	
Anderson-Darling	A-Sq 0.286868	Pr > A-Sq	>0.2500	



## Lampiran 29. Pemodelan ARIMAX Skenario 4 Replikasi 5

Conditional Least Squares Estimation							
Parameter	Estimate	Standard Error	t Value	Approx Pr >  t	Lag	Variable	Shift
AR1,1	0.16333	0.07927	2.06	0.0410	1	y	0
NUM1	0.30407	0.0068263	44.54	<.0001	0	t	0
NUM2	8.80668	1.18675	7.42	<.0001	0	M1	0
NUM3	7.75351	1.18937	6.52	<.0001	0	M2	0
NUM4	10.66315	1.19244	8.94	<.0001	0	M3	0
NUM5	12.51026	1.19579	10.46	<.0001	0	M4	0
NUM6	18.18979	1.19923	15.17	<.0001	0	M5	0
NUM7	17.02140	1.21484	14.01	<.0001	0	M6	0
NUM8	20.48187	1.24782	16.41	<.0001	0	M7	0
NUM9	18.83168	1.25156	15.05	<.0001	0	M8	0
NUM10	20.90915	1.26485	16.53	<.0001	0	M9	0
NUM11	20.47846	1.29700	15.79	<.0001	0	M10	0
NUM12	11.21905	1.28321	8.74	<.0001	0	M11	0
NUM13	8.05787	1.24259	6.48	<.0001	0	M12	0
NUM14	14.95761	2.37706	6.29	<.0001	0	C1t	0
NUM15	21.99084	2.05713	10.69	<.0001	0	C2t	0
NUM16	47.58447	2.05395	23.17	<.0001	0	C3t	0
NUM17	72.54123	2.05794	35.25	<.0001	0	C4t	0
NUM18	39.85769	2.38087	16.74	<.0001	0	C1t1	0
NUM19	24.13982	2.06177	11.71	<.0001	0	C2t1	0
NUM20	26.22388	2.06167	12.72	<.0001	0	C3t1	0
NUM21	16.98475	2.05515	8.26	<.0001	0	C4t1	0
Variance Estimate				15.60772			
Std Error Estimate				3.95066			
AIC				1025.951			
SBC				1096.196			
Number of Residuals				180			
* AIC and SBC do not include log determinant.							

Autocorrelation Check of Residuals								
Lag	Square	DF	To ChiSq	Chi-	Pr >	-----Autocorrelations-----		
6	4.32	5	0.5043	-0.008	0.045	0.043	-0.012	0.000
12	9.26	11	0.5976	0.021	0.105	-0.067	0.004	0.054
18	14.71	17	0.6163	-0.050	-0.021	-0.030	-0.113	-0.103
24	25.98	23	0.3017	0.079	-0.085	-0.016	-0.019	-0.143
30	32.19	29	0.3115	-0.053	0.079	-0.079	-0.111	0.003
36	37.02	35	0.3757	-0.078	-0.022	0.098	-0.000	-0.052

Tests for Normality			
Test	--Statistic--	-----p Value-----	
Shapiro-Wilk	W 0.991029	Pr < W	0.3236
Kolmogorov-Smirnov	D 0.035209	Pr > D	>0.1500
Cramer-von Mises	W-Sq 0.027276	Pr > W-Sq	>0.2500
Anderson-Darling	A-Sq 0.221926	Pr > A-Sq	>0.2500

Lampiran 30. Pemodelan Regresi *Time Series Outflow* Uang Kartal

Conditional Least Squares Estimation							
Parameter	Estimate	Standard Error	t Value	Approx Pr >  t	Lag	Variable	Shift
NUM1	-0.0014467	0.0070611	-0.20	0.8380	0	t	0
NUM2	-2.89283	0.31289	-9.25	<.0001	0	I1	0
NUM3	-2.61666	0.39936	-6.55	<.0001	0	I2	0
NUM4	0.02487	0.0082745	3.01	0.0032	0	tI1	0
NUM5	0.02668	0.0077442	3.45	0.0008	0	tI2	0
NUM6	-0.10034	0.18280	-0.55	0.5841	0	M1	0
NUM7	0.24450	0.18389	1.33	0.1862	0	M2	0
NUM8	0.51071	0.18501	2.76	0.0067	0	M3	0
NUM9	0.77558	0.18617	4.17	<.0001	0	M4	0
NUM10	0.59230	0.18736	3.16	0.0020	0	M5	0
NUM11	0.93240	0.19096	4.88	<.0001	0	M6	0
NUM12	0.68135	0.19594	3.48	0.0007	0	M7	0
NUM13	0.30715	0.19709	1.56	0.1218	0	M8	0
NUM14	0.48200	0.19838	2.43	0.0166	0	M9	0
NUM15	0.33776	0.20091	1.68	0.0954	0	M10	0
NUM16	0.48393	0.19880	2.43	0.0164	0	M11	0
NUM17	1.36552	0.19654	6.95	<.0001	0	M12	0
NUM18	-0.48529	0.31703	-1.53	0.1285	0	C1t	0
NUM19	1.46630	0.26131	5.61	<.0001	0	C2t	0
NUM20	1.40158	0.22557	6.21	<.0001	0	C3t	0
NUM21	1.67382	0.26381	6.34	<.0001	0	C4t	0
NUM22	1.84856	0.31833	5.81	<.0001	0	C1t1	0
NUM23	1.18810	0.26171	4.54	<.0001	0	C2t1	0
NUM24	0.23969	0.22595	1.06	0.2909	0	C3t1	0
NUM25	0.15630	0.21176	0.74	0.4619	0	C4t1	0
Variance Estimate				0.179949			
Std Error Estimate				0.424204			
AIC				184.2235			
SBC				258.4689			
Number of Residuals				144			
* AIC and SBC do not include log determinant.							

Autocorrelation Check of Residuals								
Lag	Square	DF	To ChiSq	Chi-Pr >	-----Autocorrelations-----			
6	12.93	6	0.0442	-0.183 0.170	-0.118	0.098	0.021	-0.030
12	18.54	12	0.1003	0.092 -0.019	-0.007	-0.057	-0.002	0.154
18	30.12	18	0.0363	-0.187 -0.121	-0.111	-0.009	-0.096	0.016
24	38.25	24	0.0326	-0.004 0.014	-0.045	-0.142	0.104	-0.116
30	45.92	30	0.0316	0.080 -0.119	0.113	-0.054	0.070	-0.037
36	49.04	36	0.0722	0.085 -0.008	-0.078	-0.002	-0.026	-0.049

### Lampiran 31. Pemodelan ARIMA $([2],0,[1,13])(1,0,0)^{12}$ *Outflow Uang Kartal*

Conditional Least Squares Estimation					
Parameter	Standard Estimate	Error	Approx t Value	Pr >  t	Lag
MA1,1	0.23097	0.08150	2.83	0.0053	1
MA1,2	0.28786	0.08156	3.53	0.0006	13
AR1,1	0.18855	0.08655	2.18	0.0310	2
AR2,1	0.20047	0.08589	2.33	0.0210	12
Variance Estimate			0.131423		
Std Error Estimate			0.362523		
AIC			120.3737		
SBC			132.253		
Number of Residuals			144		
* AIC and SBC do not include log determinant.					

Autocorrelation Check of Residuals									
Lag	Square	DF	To ChiSq	Chi-	Pr >	-----Autocorrelations-----			
6	2.29	2	0.3188	0.060	-0.006	-0.097	0.035	0.035	0.002
12	4.83	8	0.7756	0.093	-0.035	-0.040	-0.067	0.011	0.018
18	12.34	14	0.5791	0.039	-0.128	-0.114	-0.055	-0.096	0.051
24	20.40	20	0.4331	-0.010	0.036	-0.087	-0.173	0.040	-0.080
30	23.28	26	0.6170	0.080	-0.032	0.065	-0.046	0.025	-0.041
36	28.81	32	0.6289	0.101	-0.017	-0.027	-0.017	-0.129	-0.032

Autocorrelation Check of Residuals									
Lag	Square	DF	To ChiSq	Chi-	Pr >	-----Autocorrelations-----			
6	2.29	2	0.3188	0.060	-0.006	-0.097	0.035	0.035	0.002
12	4.83	8	0.7756	0.093	-0.035	-0.040	-0.067	0.011	0.018
18	12.34	14	0.5791	0.039	-0.128	-0.114	-0.055	-0.096	0.051
24	20.40	20	0.4331	-0.010	0.036	-0.087	-0.173	0.040	-0.080
30	23.28	26	0.6170	0.080	-0.032	0.065	-0.046	0.025	-0.041
36	28.81	32	0.6289	0.101	-0.017	-0.027	-0.017	-0.129	-0.032

## Lampiran 32. Pemodelan ARIMA $([2],0,[1,13])(0,0,1)^{12}$ Outflow Uang Kartal

The ARIMA Procedure					
Conditional Least Squares Estimation					
Parameter	Standard Estimate	Error	Approx t Value	Pr >  t	Lag
MA1,1	0.22447	0.08133	2.76	0.0066	1
MA1,2	0.28926	0.08172	3.54	0.0005	13
MA2,1	-0.22998	0.08492	-2.71	0.0076	12
AR1,1	0.18454	0.08593	2.15	0.0335	2
Variance Estimate			0.130611		
Std Error Estimate			0.361401		
AIC			119.4809		
SBC			131.3601		
Number of Residuals			144		
* AIC and SBC do not include log determinant.					

Autocorrelation Check of Residuals									
Lag	Square	DF	To ChiSq	Chi-	Pr >	-----Autocorrelations-----			
6	2.24	2	0.3258	0.058	-0.007	-0.094	0.039	0.036	0.001
12	4.91	8	0.7672	0.094	-0.042	-0.042	-0.069	0.004	-0.009
18	12.57	14	0.5605	0.036	-0.129	-0.116	-0.057	-0.098	0.051
24	19.85	20	0.4674	-0.016	0.043	-0.089	-0.167	0.050	-0.044
30	22.86	26	0.6409	0.083	-0.025	0.069	-0.044	0.036	-0.036
36	28.67	32	0.6360	0.106	-0.024	-0.024	-0.016	-0.130	-0.032

Tests for Normality				
Test	--Statistic--	-----p Value-----		
Shapiro-Wilk	W 0.990103	Pr < W	0.4051	
Kolmogorov-Smirnov	D 0.042359	Pr > D	>0.1500	
Cramer-von Mises	W-Sq 0.045436	Pr > W-Sq	>0.2500	
Anderson-Darling	A-Sq 0.333272	Pr > A-Sq	>0.2500	

### Lampiran 33. Pemodelan ARIMA ([1,2,13,14],0,0)(1,0,0)<sup>12</sup> Outflow Uang Kartal

Conditional Least Squares Estimation					
Parameter	Standard Estimate	Error	Approx t Value	Pr >  t	Lag
AR1,1	-0.16576	0.08129	-2.04	0.0433	1
AR1,2	0.19332	0.08025	2.41	0.0173	2
AR1,3	-0.22504	0.08158	-2.76	0.0066	13
AR1,4	-0.21467	0.08299	-2.59	0.0107	14
AR2,1	0.19740	0.08621	2.29	0.0235	12
Variance Estimate			0.129708		
Std Error Estimate			0.360149		
AIC			119.4493		
SBC			134.2984		
Number of Residuals			144		
* AIC and SBC do not include log determinant					

Autocorrelation Check of Residuals									
Lag	Square	DF	To ChiSq	Chi-	Pr > Autocorrelations-----				
6	1.90	1	0.1684	-0.013	-0.039	-0.077	0.054	0.043	-0.013
12	4.91	7	0.6712	0.108	-0.054	-0.002	-0.057	0.034	0.020
18	8.68	13	0.7966	0.004	-0.029	-0.093	-0.015	-0.097	0.061
24	17.17	19	0.5784	-0.027	0.032	-0.090	-0.170	0.050	-0.089
30	21.15	25	0.6840	0.078	-0.095	0.001	-0.070	0.013	-0.045
36	25.14	31	0.7615	0.076	-0.011	-0.037	0.002	-0.114	-0.025

Tests for Normality				
Test	--Statistic--	----p Value-----		
Shapiro-Wilk	W	0.985805	Pr < W	0.1455
Kolmogorov-Smirnov	D	0.050444	Pr > D	>0.1500
Cramer-von Mises	W-Sq	0.08255	Pr > W-Sq	0.1980
Anderson-Darling	A-Sq	0.54477	Pr > A-Sq	0.1647

### Lampiran 34. Pemodelan ARIMA (1,0,[13])(0,0,1)<sup>12</sup> Outflow Uang Kartal

The ARIMA Procedure					
Conditional Least Squares Estimation					
Parameter	Standard Estimate	Error	Approx t Value	Pr >  t	Lag
MA1,1	0.28357	0.08324	3.41	0.0009	13
MA2,1	-0.19875	0.08481	-2.34	0.0205	12
AR1,1	-0.19430	0.08264	-2.35	0.0201	1
Variance Estimate			0.13499		
Std Error Estimate			0.36741		
AIC			123.2547		
SBC			132.1642		
Number of Residuals			144		
* AIC and SBC do not include log determinant.					

Autocorrelation Check of Residuals									
Lag	Square	DF	To ChiSq	Chi-	Pr >	Autocorrelations-----			
6	4.69	3	0.1960	0.030	0.138	-0.079	0.060	0.042	0.007
12	7.36	9	0.6002	0.094	-0.034	-0.030	-0.077	0.007	-0.015
18	19.23	15	0.2033	0.018	-0.187	-0.132	-0.068	-0.117	0.042
24	26.85	21	0.1759	-0.041	0.024	-0.075	-0.164	0.053	-0.080
30	31.73	27	0.2422	0.099	-0.053	0.072	-0.053	0.067	-0.045
36	37.68	33	0.2636	0.112	-0.038	-0.028	-0.016	-0.125	-0.024

Tests for Normality				
Test	--Statistic--	-----p Value-----		
Shapiro-Wilk	W 0.990403	Pr < W	0.4323	
Kolmogorov-Smirnov	D 0.0564	Pr > D	>0.1500	
Cramer-von Mises	W-Sq 0.080468	Pr > W-Sq	0.2103	
Anderson-Darling	A-Sq 0.452197	Pr > A-Sq	>0.2500	

### Lampiran 35. Pemodelan ARIMAX ke-1 *Outflow* Uang Kartal (Semua Parameter)

Conditional Least Squares Estimation							
Parameter	Estimate	Standard Error	t Value	Approx Pr >  t	Lag	Variable	Shift
MA1,1	0.28535	0.08993	3.17	0.0019	1	y	0
MA1,2	0.34852	0.09052	3.85	0.0002	13	y	0
AR1,1	0.26399	0.09863	2.68	0.0085	2	y	0
AR2,1	0.20507	0.09804	2.09	0.0387	12	y	0
NUM1	-0.0033736	0.0064305	-0.52	0.6009	0	t	0
NUM2	-2.85715	0.27173	-10.51	<.0001	0	I1	0
NUM3	-2.66011	0.33783	-7.87	<.0001	0	I2	0
NUM4	0.02575	0.0072312	3.56	0.0005	0	tI1	0
NUM5	0.02864	0.0069493	4.12	<.0001	0	tI2	0
NUM6	0.0006179	0.19856	0.00	0.9975	0	M1	0
NUM7	0.25491	0.20291	1.26	0.2116	0	M2	0
NUM8	0.54905	0.20500	2.68	0.0085	0	M3	0
NUM9	0.82443	0.20567	4.01	0.0001	0	M4	0
NUM10	0.61659	0.20673	2.98	0.0035	0	M5	0
NUM11	0.90625	0.21045	4.31	<.0001	0	M6	0
NUM12	0.70658	0.21316	3.31	0.0012	0	M7	0
NUM13	0.38675	0.21325	1.81	0.0723	0	M8	0
NUM14	0.56649	0.21430	2.64	0.0094	0	M9	0
NUM15	0.46728	0.21849	2.14	0.0346	0	M10	0
NUM16	0.58592	0.21330	2.75	0.0070	0	M11	0
NUM17	1.31581	0.21424	6.14	<.0001	0	M12	0
NUM18	-0.72536	0.27051	-2.68	0.0084	0	C1t	0
NUM19	1.46732	0.22968	6.39	<.0001	0	C2t	0
NUM20	1.09735	0.20182	5.44	<.0001	0	C3t	0
NUM21	1.44893	0.24033	6.03	<.0001	0	C4t	0
NUM22	1.63427	0.28002	5.84	<.0001	0	C1t1	0
NUM23	1.00685	0.23057	4.37	<.0001	0	C2t1	0
NUM24	0.27637	0.20362	1.36	0.1773	0	C3t1	0
NUM25	0.47174	0.19658	2.40	0.0180	0	C4t1	0
Variance Estimate				0.152432			
Std Error Estimate				0.390425			
AIC				163.4018			
SBC				249.5264			
Number of Residuals				144			
* AIC and SBC do not include log determinant.							

The ARIMA Procedure									
Autocorrelation Check of Residuals									
Lag	Square	DF	To ChiSq	Chi-	Pr >	-----Autocorrelations-----			
6	0.59	2	0.7446	0.060	0.003	-0.014	-0.011	0.010	0.005
12	2.08	8	0.9785	0.074	-0.038	-0.016	-0.046	0.001	0.019
18	8.67	14	0.8518	0.008	-0.099	-0.097	-0.056	-0.132	0.021
24	18.42	20	0.5597	-0.042	0.009	-0.046	-0.216	0.009	-0.077
30	20.58	26	0.7634	0.056	0.052	0.043	-0.023	0.029	-0.054
36	23.47	32	0.8631	0.068	0.007	-0.015	-0.034	-0.087	-0.040

Tests for Normality				
Test	--Statistic--	----p Value----		
Shapiro-Wilk	W	0.994019	Pr < W	0.8158
Kolmogorov-Smirnov	D	0.043058	Pr > D	>0.1500
Cramer-von Mises	W-Sq	0.034257	Pr > W-Sq	>0.2500
Anderson-Darling	A-Sq	0.224733	Pr > A-Sq	>0.2500

## Lampiran 36. Pemodelan ARIMAX ke-2 *Outflow* Uang Kartal (Semua Parameter)

Conditional Least Squares Estimation							
Parameter	Estimate	Standard Error	t Value	Approx Pr >  t	Lag	Variable	Shift
MA1,1	0.28035	0.08988	3.12	0.0023	1	y	0
MA1,2	0.34693	0.09079	3.82	0.0002	13	y	0
MA2,1	-0.24046	0.09595	-2.51	0.0136	12	y	0
AR1,1	0.26178	0.09833	2.66	0.0089	2	y	0
NUM1	-0.0033971	0.0065722	-0.52	0.6062	0	t	0
NUM2	-2.88648	0.27928	-10.34	<.0001	0	I1	0
NUM3	-2.69609	0.34367	-7.85	<.0001	0	I2	0
NUM4	0.02629	0.0074326	3.54	0.0006	0	tI1	0
NUM5	0.02896	0.0070967	4.08	<.0001	0	tI2	0
NUM6	-0.0039349	0.19814	-0.02	0.9842	0	M1	0
NUM7	0.25561	0.20232	1.26	0.2090	0	M2	0
NUM8	0.55073	0.20443	2.69	0.0081	0	M3	0
NUM9	0.82678	0.20514	4.03	0.0001	0	M4	0
NUM10	0.61626	0.20615	2.99	0.0034	0	M5	0
NUM11	0.90712	0.20998	4.32	<.0001	0	M6	0
NUM12	0.70333	0.21270	3.31	0.0013	0	M7	0
NUM13	0.39079	0.21292	1.84	0.0690	0	M8	0
NUM14	0.56325	0.21382	2.63	0.0096	0	M9	0
NUM15	0.46699	0.21783	2.14	0.0342	0	M10	0
NUM16	0.58492	0.21273	2.75	0.0069	0	M11	0
NUM17	1.31947	0.21399	6.17	<.0001	0	M12	0
NUM18	-0.70356	0.26913	-2.61	0.0101	0	C1t	0
NUM19	1.45218	0.22724	6.39	<.0001	0	C2t	0
NUM20	1.08284	0.20135	5.38	<.0001	0	C3t	0
NUM21	1.42861	0.23908	5.98	<.0001	0	C4t	0
NUM22	1.63922	0.27805	5.90	<.0001	0	C1t1	0
NUM23	1.02307	0.23092	4.43	<.0001	0	C2t1	0
NUM24	0.27878	0.20240	1.38	0.1711	0	C3t1	0
NUM25	0.48605	0.19809	2.45	0.0156	0	C4t1	0
Variance Estimate				0.151418			
Std Error Estimate				0.389124			
AIC				162.4407			
SBC				248.5653			
Number of Residuals				144			
* AIC and SBC do not include log determinant.							

Autocorrelation Check of Residuals									
Lag	Square	DF	To ChiSq	Chi-	Pr >	-----Autocorrelations-----			
6	0.54	2	0.7635	0.057	0.002	-0.007	-0.005	0.016	0.005
12	1.96	8	0.9823	0.075	-0.039	-0.013	-0.043	-0.004	-0.010
18	8.45	14	0.8644	0.006	-0.097	-0.099	-0.056	-0.130	0.023
24	17.35	20	0.6302	-0.049	0.013	-0.044	-0.211	0.014	-0.048
30	19.68	26	0.8065	0.054	0.058	0.045	-0.025	0.039	-0.051
36	22.62	32	0.8899	0.067	-0.002	-0.016	-0.036	-0.087	-0.043

Tests for Normality				
Test	--Statistic--	-----p Value-----		
Shapiro-Wilk	W	0.994045	Pr < W	0.8184
Kolmogorov-Smirnov	D	0.047347	Pr > D	>0.1500
Cramer-von Mises	W-Sq	0.033035	Pr > W-Sq	>0.2500
Anderson-Darling	A-Sq	0.223818	Pr > A-Sq	>0.2500



### Lampiran 37. Pemodelan ARIMAX ke-3 *Outflow* Uang Kartal (Semua Parameter)

Conditional Least Squares Estimation

Parameter	Estimate	Standard Error	t Value	Approx Pr >  t	Lag	Variable	Shift	
AR1,1	-0.19853	0.08952	-2.22	0.0286	1	y	0	
AR1,2	0.24018	0.08765	2.74	0.0071	2	y	0	
AR1,3	-0.32261	0.08823	-3.66	0.0004	13	y	0	
AR1,4	-0.24240	0.09178	-2.64	0.0094	14	y	0	
AR2,1	0.20674	0.09772	2.12	0.0366	12	y	0	
NUM1	-0.0049618	0.0060803	-0.82	0.4162	0	t	0	
NUM2	-2.72286	0.25367	-10.73	<.0001	0	I1	0	
NUM3	-2.56767	0.32626	-7.87	<.0001	0	I2	0	
NUM4	0.02465	0.0067580	3.65	0.0004	0	tI1	0	
NUM5	0.02924	0.0065699	4.45	<.0001	0	tI2	0	
NUM6	0.0005649	0.19094	0.00	0.9976	0	M1	0	
NUM7	0.27343	0.19517	1.40	0.1639	0	M2	0	
NUM8	0.56887	0.19702	2.89	0.0046	0	M3	0	
NUM9	0.84647	0.19794	4.28	<.0001	0	M4	0	
NUM10	0.64789	0.19906	3.25	0.0015	0	M5	0	
NUM11	0.92628	0.20271	4.57	<.0001	0	M6	0	
NUM12	0.71984	0.20538	3.50	0.0007	0	M7	0	
NUM13	0.38280	0.20570	1.86	0.0653	0	M8	0	
NUM14	0.58103	0.20610	2.82	0.0057	0	M9	0	
NUM15	0.48684	0.21112	2.31	0.0229	0	M10	0	
NUM16	0.60563	0.20611	2.94	0.0040	0	M11	0	
NUM17	1.37241	0.20628	6.65	<.0001	0	M12	0	
NUM18	-0.70317	0.26530	-2.65	0.0092	0	C1t	0	
NUM19	1.49513	0.22382	6.68	<.0001	0	C2t	0	
NUM20	1.12584	0.19960	5.64	<.0001	0	C3t	0	
NUM21	1.53978	0.23507	6.55	<.0001	0	C4t	0	
NUM22	1.63179	0.27483	5.94	<.0001	0	C1t1	0	
NUM23	1.08264	0.22981	4.71	<.0001	0	C2t1	0	
NUM24	0.28593	0.20078	1.42	0.1571	0	C3t1	0	
NUM25	0.47216	0.19704	2.40	0.0182	0	C4t1	0	
Variance Estimate				0.151081				
Std Error Estimate				0.388691				
AIC				162.8622				
SBC				251.9566				
Number of Residuals				144				
* AIC and SBC do not include log determinant.								

Autocorrelation Check of Residuals

Lag	Square	DF	To ChiSq	Chi-	Pr >	-----Autocorrelations-----			
6	0.38	1	0.5363	-0.034	-0.025	0.008	0.007	0.026	-0.003
12	2.79	7	0.9036	0.089	-0.075	0.009	-0.036	0.016	0.020
18	7.36	13	0.8825	0.001	-0.044	-0.078	-0.027	-0.134	0.031
24	17.65	19	0.5462	-0.071	0.009	-0.040	-0.212	0.017	-0.088
30	19.89	25	0.7526	0.063	-0.036	-0.033	-0.053	0.020	-0.054
36	21.34	31	0.9028	0.062	0.005	-0.012	0.011	-0.057	-0.017

Tests for Normality

Test	--Statistic--	----p Value----		
Shapiro-Wilk	W	0.989327	Pr < W	0.3406
Kolmogorov-Smirnov	D	0.046197	Pr > D	>0.1500
Cramer-von Mises	W-Sq	0.03766	Pr > W-Sq	>0.2500
Anderson-Darling	A-Sq	0.300399	Pr > A-Sq	>0.2500

Lampiran 38. Pemodelan ARIMAX ke-4 *Outflow* Uang Kartal  
(Semua Parameter)

Conditional Least Squares Estimation							
Parameter	Estimate	Standard Error	t Value	Approx Pr >  t	Lag	Variable	Shift
MA1,1	0.33807	0.09265	3.65	0.0004	13	y	0
MA2,1	-0.20713	0.09523	-2.17	0.0317	12	y	0
AR1,1	-0.24353	0.09141	-2.66	0.0088	1	y	0
NUM1	-0.0008102	0.0056626	-0.14	0.8865	0	t	0
NUM2	-2.87838	0.24024	-11.98	<.0001	0	I1	0
NUM3	-2.59362	0.30194	-8.59	<.0001	0	I2	0
NUM4	0.02398	0.0063958	3.75	0.0003	0	tI1	0
NUM5	0.02593	0.0061570	4.21	<.0001	0	tI2	0
NUM6	-0.05862	0.18469	-0.32	0.7515	0	M1	0
NUM7	0.22655	0.18902	1.20	0.2332	0	M2	0
NUM8	0.50109	0.18949	2.64	0.0093	0	M3	0
NUM9	0.79482	0.19040	4.17	<.0001	0	M4	0
NUM10	0.57038	0.19087	2.99	0.0034	0	M5	0
NUM11	0.88952	0.19468	4.57	<.0001	0	M6	0
NUM12	0.67078	0.19753	3.40	0.0009	0	M7	0
NUM13	0.36282	0.19808	1.83	0.0696	0	M8	0
NUM14	0.49962	0.19977	2.50	0.0138	0	M9	0
NUM15	0.41980	0.20147	2.08	0.0394	0	M10	0
NUM16	0.50906	0.19831	2.57	0.0115	0	M11	0
NUM17	1.29409	0.19904	6.50	<.0001	0	M12	0
NUM18	-0.56620	0.28558	-1.98	0.0498	0	C1t	0
NUM19	1.44457	0.24210	5.97	<.0001	0	C2t	0
NUM20	1.16323	0.21288	5.46	<.0001	0	C3t	0
NUM21	1.39548	0.25080	5.56	<.0001	0	C4t	0
NUM22	1.73018	0.29373	5.89	<.0001	0	C1t1	0
NUM23	1.02285	0.24658	4.15	<.0001	0	C2t1	0
NUM24	0.20872	0.21327	0.98	0.3298	0	C3t1	0
NUM25	0.41120	0.20891	1.97	0.0514	0	C4t1	0
Variance Estimate				0.159156			
Std Error Estimate				0.398944			
AIC				168.8649			
SBC				252.0197			
Number of Residuals				144			

Autocorrelation Check of Residuals									
Lag	Square	DF	To ChiSq	Chi-	Pr > -----Autocorrelations-----				
6	3.83	3	0.2802	0.037	0.148	-0.017	0.035	0.032	0.000
12	5.55	9	0.7838	0.081	-0.014	-0.010	-0.062	-0.010	-0.018
18	18.27	15	0.2485	-0.002	-0.178	-0.141	-0.071	-0.144	0.025
24	27.84	21	0.1448	-0.061	-0.004	-0.037	-0.204	0.027	-0.090
30	30.39	27	0.2971	0.063	0.007	0.039	-0.034	0.067	-0.054
36	34.08	33	0.4154	0.083	-0.030	-0.022	-0.040	-0.094	-0.028

Tests for Normality				
Test	--Statistic--	-----p Value-----		
Shapiro-Wilk	W	0.995091	Pr < W	0.9109
Kolmogorov-Smirnov	D	0.052366	Pr > D	>0.1500
Cramer-von Mises	W-Sq	0.038224	Pr > W-Sq	>0.2500
Anderson-Darling	A-Sq	0.215326	Pr > A-Sq	>0.2500

Lampiran 39. Pemodelan ARIMAX ke-1 *Outflow* Uang Kartal  
(Parameter Signifikan)

Conditional Least Squares Estimation							
Parameter	Estimate	Standard Error	t Value	Approx Pr >  t	Lag	Variable	Shift
MA1,1	0.29213	0.08926	3.27	0.0014	1	y	0
MA1,2	0.32742	0.08808	3.72	0.0003	13	y	0
AR1,1	0.22191	0.09539	2.33	0.0216	2	y	0
AR2,1	0.31590	0.09332	3.39	0.0010	12	y	0
NUM1	-2.85180	0.24966	-11.42	<.0001	0	I1	0
NUM2	-2.53745	0.31975	-7.94	<.0001	0	I2	0
NUM3	0.02421	0.0039189	6.18	<.0001	0	tI1	0
NUM4	0.02541	0.0027498	9.24	<.0001	0	tI2	0
NUM5	0.52113	0.17837	2.92	0.0041	0	M3	0
NUM6	0.67991	0.18987	3.58	0.0005	0	M4	0
NUM7	0.55575	0.19626	2.83	0.0054	0	M5	0
NUM8	0.84199	0.18947	4.44	<.0001	0	M6	0
NUM9	0.79328	0.18452	4.30	<.0001	0	M7	0
NUM10	0.70265	0.17685	3.97	0.0001	0	M9	0
NUM11	0.54099	0.17560	3.08	0.0025	0	M11	0
NUM12	1.08546	0.17573	6.18	<.0001	0	M12	0
NUM13	1.68433	0.23138	7.28	<.0001	0	C2t	0
NUM14	1.30002	0.21058	6.17	<.0001	0	C3t	0
NUM15	1.65179	0.24553	6.73	<.0001	0	C4t	0
NUM16	1.57431	0.28508	5.52	<.0001	0	C1t1	0
NUM17	0.86427	0.23107	3.74	0.0003	0	C2t1	0
Variance Estimate				0.162771			
Std Error Estimate				0.403449			
AIC				166.5366			
SBC				228.9026			
Number of Residuals				144			
* AIC and SBC do not include log determinant.							

Autocorrelation Check of Residuals									
Lag	Square	DF	To ChiSq	Chi-	Pr > Autocorrelations-----				
6	1.89	2	0.3883	0.064	-0.012	-0.072	0.055	-0.012	0.010
12	4.56	8	0.8037	0.105	-0.019	-0.029	-0.069	0.011	0.009
18	10.55	14	0.7206	0.038	-0.110	-0.104	0.011	-0.093	0.058
24	16.07	20	0.7125	-0.012	0.060	-0.125	-0.106	0.032	-0.024
30	18.14	26	0.8705	-0.008	-0.009	0.085	-0.033	-0.029	-0.046
36	24.26	32	0.8348	0.106	0.001	-0.085	-0.019	-0.112	0.027

Tests for Normality				
Test	--Statistic--	----p Value-----		
Shapiro-Wilk	W	0.997368	Pr < W	0.9971
Kolmogorov-Smirnov	D	0.038006	Pr > D	>0.1500
Cramer-von Mises	W-Sq	0.024526	Pr > W-Sq	>0.2500
Anderson-Darling	A-Sq	0.150902	Pr > A-Sq	>0.2500

## Lampiran 40. Pemodelan ARIMAX ke-2 *Outflow* Uang Kartal (Parameter Signifikan)

Conditional Least Squares Estimation							
Parameter	Estimate	Standard Error	t Value	Approx Pr >  t	Lag	Variable	Shift
MA1,1	0.28172	0.09005	3.13	0.0022	1	y	0
MA1,2	0.32191	0.08908	3.61	0.0004	13	y	0
MA2,1	-0.31946	0.09061	-3.53	0.0006	12	y	0
AR1,1	0.20910	0.09526	2.19	0.0300	2	y	0
NUM1	-2.89331	0.25533	-11.33	<.0001	0	I1	0
NUM2	-2.58660	0.32263	-8.02	<.0001	0	I2	0
NUM3	0.02493	0.0040257	6.19	<.0001	0	tI1	0
NUM4	0.02583	0.0027811	9.29	<.0001	0	tI2	0
NUM5	0.52231	0.16598	3.15	0.0021	0	M3	0
NUM6	0.68177	0.17500	3.90	0.0002	0	M4	0
NUM7	0.55280	0.18059	3.06	0.0027	0	M5	0
NUM8	0.84527	0.17454	4.84	<.0001	0	M6	0
NUM9	0.79357	0.17183	4.62	<.0001	0	M7	0
NUM10	0.68860	0.16660	4.13	<.0001	0	M9	0
NUM11	0.54636	0.16333	3.35	0.0011	0	M11	0
NUM12	1.09768	0.16354	6.71	<.0001	0	M12	0
NUM13	1.65999	0.22917	7.24	<.0001	0	C2t	0
NUM14	1.28098	0.20847	6.14	<.0001	0	C3t	0
NUM15	1.62427	0.24574	6.61	<.0001	0	C4t	0
NUM16	1.63636	0.28385	5.76	<.0001	0	C1t1	0
NUM17	0.91941	0.23076	3.98	0.0001	0	C2t1	0
Variance Estimate				0.162796			
Std Error Estimate				0.40348			
AIC				166.5588			
SBC				228.9248			
Number of Residuals				144			
* AIC and SBC do not include log determinant.							

Autocorrelation Check of Residuals									
Lag	Square	DF	To ChiSq	Chi-	Pr >	-----Autocorrelations-----			
6	2.23	2	0.3286	0.060	-0.014	-0.081	0.065	-0.006	0.015
12	5.07	8	0.7506	0.105	-0.011	-0.037	-0.076	-0.003	0.007
18	10.98	14	0.6876	0.034	-0.099	-0.112	0.007	-0.091	0.066
24	16.68	20	0.6735	-0.020	0.070	-0.129	-0.091	0.042	0.037
30	18.44	26	0.8593	-0.013	-0.004	0.081	-0.033	-0.027	-0.034
36	24.71	32	0.8177	0.099	-0.012	-0.093	-0.026	-0.116	0.021

Tests for Normality				
Test	--Statistic--	-----p Value-----		
Shapiro-Wilk	W	0.99741	Pr < W	0.9974
Kolmogorov-Smirnov	D	0.036887	Pr > D	>0.1500
Cramer-von Mises	W-Sq	0.021069	Pr > W-Sq	>0.2500
Anderson-Darling	A-Sq	0.135067	Pr > A-Sq	>0.2500

Lampiran 41. Pemodelan ARIMAX ke-3 *Outflow* Uang Kartal  
(Parameter Signifikan)

Conditional Least Squares Estimation							
Parameter	Estimate	Standard Error	t Value	Approx Pr >  t	Lag	Variable	Shift
AR1,1	-0.19100	0.09018	-2.12	0.0362	1	y	0
AR1,2	0.19763	0.08776	2.25	0.0261	2	y	0
AR1,3	-0.25402	0.08807	-2.88	0.0046	13	y	0
AR1,4	-0.23314	0.09098	-2.56	0.0116	14	y	0
AR2,1	0.31184	0.09286	3.36	0.0010	12	y	0
NUM1	-2.74433	0.24780	-11.07	<.0001	0	I1	0
NUM2	-2.44935	0.32961	-7.43	<.0001	0	I2	0
NUM3	0.02254	0.0039304	5.73	<.0001	0	tI1	0
NUM4	0.02479	0.0028316	8.76	<.0001	0	tI2	0
NUM5	0.48188	0.17483	2.76	0.0067	0	M3	0
NUM6	0.68048	0.17942	3.79	0.0002	0	M4	0
NUM7	0.53697	0.18318	2.93	0.0040	0	M5	0
NUM8	0.84851	0.17777	4.77	<.0001	0	M6	0
NUM9	0.72665	0.18061	4.02	<.0001	0	M7	0
NUM10	0.60909	0.17971	3.39	0.0009	0	M9	0
NUM11	0.47824	0.17522	2.73	0.0073	0	M11	0
NUM12	1.11095	0.17316	6.42	<.0001	0	M12	0
NUM13	1.70663	0.22523	7.58	<.0001	0	C2t	0
NUM14	1.34363	0.20915	6.42	<.0001	0	C3t	0
NUM15	1.71465	0.24146	7.10	<.0001	0	C4t	0
NUM16	1.62792	0.27968	5.82	<.0001	0	C1t1	0
NUM17	0.95440	0.22982	4.15	<.0001	0	C2t1	0
Variance Estimate				0.161494			
Std Error Estimate				0.401863			
AIC				166.2267			
SBC				231.5626			
Number of Residuals				144			
* AIC and SBC do not include log determinant.							
a							

Autocorrelation Check of Residuals									
Lag	Square	DF	To ChiSq	Chi-	Pr > Autocorrelations-----				
6	1.46	1	0.2272	-0.017	-0.036	-0.057	0.070	-0.003	-0.005
12	4.94	7	0.6669	0.121	-0.043	-0.008	-0.070	0.034	0.005
18	9.52	13	0.7328	0.013	-0.040	-0.100	0.044	-0.100	0.064
24	15.12	19	0.7150	-0.042	0.065	-0.125	-0.095	0.041	-0.023
30	17.54	25	0.8614	-0.000	-0.084	0.037	-0.052	-0.033	-0.036
36	23.77	31	0.8197	0.106	0.001	-0.089	0.008	-0.100	0.060

Tests for Normality				
Test	--Statistic--	----p Value-----		
Shapiro-Wilk	W	0.993111	Pr < W	0.7189
Kolmogorov-Smirnov	D	0.062024	Pr > D	>0.1500
Cramer-von Mises	W-Sq	0.069063	Pr > W-Sq	>0.2500
Anderson-Darling	A-Sq	0.390544	Pr > A-Sq	>0.2500

## Lampiran 42. Pemodelan ARIMAX ke-4 *Outflow* Uang Kartal (Parameter Signifikan)

Conditional Least Squares Estimation							
Parameter	Estimate	Standard Error	t Value	Approx Pr >  t	Lag	Variable	Shift
MA1,1	0.29404	0.09189	3.20	0.0017	13	y	0
MA2,1	-0.29594	0.09006	-3.29	0.0013	12	y	0
AR1,1	-0.23151	0.09118	-2.54	0.0124	1	y	0
NUM1	-2.92569	0.23427	-12.49	<.0001	0	I1	0
NUM2	-2.56173	0.30243	-8.47	<.0001	0	I2	0
NUM3	0.02527	0.0037074	6.82	<.0001	0	tI1	0
NUM4	0.02566	0.0025976	9.88	<.0001	0	tI2	0
NUM5	0.49861	0.16484	3.02	0.0030	0	M3	0
NUM6	0.71403	0.16979	4.21	<.0001	0	M4	0
NUM7	0.51721	0.17245	3.00	0.0033	0	M5	0
NUM8	0.88469	0.17026	5.20	<.0001	0	M6	0
NUM9	0.76256	0.16928	4.50	<.0001	0	M7	0
NUM10	0.63515	0.16965	3.74	0.0003	0	M9	0
NUM11	0.49107	0.16401	2.99	0.0033	0	M11	0
NUM12	1.14988	0.16216	7.09	<.0001	0	M12	0
NUM13	1.66921	0.23778	7.02	<.0001	0	C2t	0
NUM14	1.33023	0.21646	6.15	<.0001	0	C3t	0
NUM15	1.60984	0.24878	6.47	<.0001	0	C4t	0
NUM16	1.80416	0.29167	6.19	<.0001	0	C1t1	0
NUM17	0.96238	0.24140	3.99	0.0001	0	C2t1	0
Variance Estimate				0.167982			
Std Error Estimate				0.409856			
AIC				170.2402			
SBC				229.6365			
Number of Residuals				144			
* AIC and SBC do not include log determinant.							

Autocorrelation Check of Residuals									
Lag	Square	DF	To ChiSq	Chi-	Pr >	-----Autocorrelations-----			
6	4.02	3	0.2589	0.031	0.113	-0.079	0.081	0.008	0.017
12	7.06	9	0.6311	0.102	-0.007	-0.025	-0.092	0.004	-0.002
18	16.85	15	0.3277	0.015	-0.164	-0.124	-0.011	-0.107	0.078
24	21.05	21	0.4557	-0.032	0.064	-0.103	-0.086	0.038	0.007
30	22.73	27	0.6997	0.011	-0.029	0.070	-0.041	0.015	-0.040
36	29.81	33	0.6267	0.091	-0.033	-0.094	-0.029	-0.129	0.039

Tests for Normality					
Test	--Statistic--	-----p Value-----			
Shapiro-Wilk	W	0.992889	Pr < W	0.6942	
Kolmogorov-Smirnov	D	0.064976	Pr > D	0.1402	
Cramer-von Mises	W-Sq	0.067233	Pr > W-Sq	>0.2500	
Anderson-Darling	A-Sq	0.379198	Pr > A-Sq	>0.2500	

### Lampiran 43. Pemodelan Regresi *Time Series Inflow* Uang Kartal

Conditional Least Squares Estimation							
Parameter	Estimate	Standard Error	t Value	Approx Pr >  t	Lag	Variable	Shift
NUM1	-0.0054395	0.0023139	-2.35	0.0204	0	t	0
NUM2	-1.95244	0.17805	-10.97	<.0001	0	I1	0
NUM3	-0.83933	0.24230	-3.46	0.0007	0	I2	0
NUM4	0.02309	0.0035448	6.52	<.0001	0	tI1	0
NUM5	0.01653	0.0030637	5.39	<.0001	0	tI2	0
NUM6	1.57008	0.09830	15.97	<.0001	0	M1	0
NUM7	1.21249	0.09872	12.28	<.0001	0	M2	0
NUM8	1.24007	0.09376	13.23	<.0001	0	M3	0
NUM9	1.11121	0.09400	11.82	<.0001	0	M4	0
NUM10	1.12675	0.09425	11.95	<.0001	0	M5	0
NUM11	1.10409	0.09453	11.68	<.0001	0	M6	0
NUM12	1.24356	0.09676	12.85	<.0001	0	M7	0
NUM13	1.27923	0.09901	12.92	<.0001	0	M8	0
NUM14	1.17313	0.09930	11.81	<.0001	0	M9	0
NUM15	1.31358	0.10066	13.05	<.0001	0	M10	0
NUM16	1.22266	0.10187	12.00	<.0001	0	M11	0
NUM17	0.87904	0.09905	8.88	<.0001	0	M12	0
NUM18	0.96232	0.18917	5.09	<.0001	0	C1t	0
NUM19	0.61001	0.15527	3.93	0.0001	0	C2t	0
NUM20	0.18948	0.13385	1.42	0.1595	0	C3t	0
NUM21	-0.27528	0.15504	-1.78	0.0784	0	C4t	0
NUM22	0.31752	0.18832	1.69	0.0944	0	C1tp1	0
NUM23	0.34543	0.15529	2.22	0.0280	0	C2tp1	0
NUM24	0.46068	0.13362	3.45	0.0008	0	C3tp1	0
NUM25	0.53845	0.13459	4.00	0.0001	0	C4tp1	0
Variance Estimate				0.063576			
Std Error Estimate				0.252143			
AIC				34.40013			
SBC				108.6455			
Number of Residuals				144			
* AIC and SBC do not include log determinant.							

Autocorrelation Check of Residuals									
Lag	Square	DF	To ChiSq	Chi-	Pr >	-----Autocorrelations-----			
6	16.98	6	0.0093	0.002	0.076	0.276	-0.061	0.091	0.139
12	22.25	12	0.0348	-0.138	0.055	-0.004	-0.064	-0.034	-0.082
18	27.13	18	0.0766	-0.005	-0.028	-0.067	-0.140	-0.025	-0.064
24	44.42	24	0.0068	-0.100	-0.020	-0.096	-0.148	0.141	-0.196
30	54.66	30	0.0039	-0.023	0.099	-0.158	0.115	0.013	-0.089
36	56.88	36	0.0148	0.035	-0.055	0.035	-0.048	-0.001	-0.063

Lampiran 44. Pemodelan ARIMA ([3],0,0) (0,0,1)<sup>24</sup> Inflow Uang Kartal

Conditional Least Squares Estimation					
Parameter	Estimate	Standard Error	t Value	Approx Pr >  t	Lag
MA1,1	0.21629	0.08550	2.53	0.0125	24
AR1,1	0.24481	0.08179	2.99	0.0033	3
Variance Estimate			0.047574		
Std Error Estimate			0.218114		
AIC			-27.9085		
SBC			-21.9689		
Number of Residuals			144		
* AIC and SBC do not include log determinant.					

Autocorrelation Check of Residuals									
Lag	Square	DF	To ChiSq	Chi-	Pr >	-----Autocorrelations-----			
6	2.14	4	0.7097	0.023	0.057	-0.015	-0.015	0.070	0.071
12	8.13	10	0.6163	-0.138	0.007	-0.014	-0.054	-0.038	-0.121
18	12.52	16	0.7072	0.057	-0.018	-0.042	-0.142	-0.030	-0.018
24	18.69	22	0.6643	-0.004	-0.051	-0.048	-0.102	0.142	0.019
30	25.75	28	0.5865	-0.023	0.079	-0.101	0.137	0.004	-0.060
36	32.02	34	0.5649	-0.028	-0.054	0.070	-0.095	-0.020	-0.121

Tests for Normality				
Test	--Statistic--	-----p Value-----		
Shapiro-Wilk	W	0.989695	Pr < W	0.3701
Kolmogorov-Smirnov	D	0.04613	Pr > D	>0.1500
Cramer-von Mises	W-Sq	0.05519	Pr > W-Sq	>0.2500
Anderson-Darling	A-Sq	0.408436	Pr > A-Sq	>0.2500



Lampiran 45. Pemodelan ARIMA (0,0,[3,16])(1,0,0)<sup>24</sup> Inflow  
Uang Kartal

Conditional Least Squares Estimation					
Parameter	Standard Estimate	Error	Approx t Value	Pr >  t	Lag
MA1,1	-0.22028	0.08151	-2.70	0.0077	3
MA1,2	0.17285	0.08291	2.08	0.0389	16
AR1,1	-0.18395	0.08591	-2.14	0.0340	24
Variance Estimate			0.047566		
Std Error Estimate			0.218097		
AIC			-26.948		
SBC			-18.0386		
Number of Residuals			144		
* AIC and SBC do not include log determinant.					

Autocorrelation Check of Residuals									
Lag	Square	DF	To ChiSq	Chi-		Pr > Autocorrelations-----			
6	2.90	3	0.4071	0.013	0.046	0.027	-0.053	0.060	0.099
12	6.96	9	0.6408	-0.119	0.018	-0.043	-0.035	-0.042	-0.082
18	8.16	15	0.9172	0.051	-0.020	-0.053	0.006	-0.013	-0.037
24	13.53	21	0.8889	-0.049	-0.074	-0.030	-0.086	0.120	-0.022
30	19.61	27	0.8467	-0.027	0.076	-0.103	0.118	0.014	-0.049
36	24.97	33	0.8411	-0.023	-0.063	0.047	-0.092	-0.022	-0.111

Tests for Normality				
Test	--Statistic--		-----p Value-----	
Shapiro-Wilk	W	0.98508	Pr < W	0.1212
Kolmogorov-Smirnov	D	0.067752	Pr > D	0.1021
Cramer-von Mises	W-Sq	0.088071	Pr > W-Sq	0.1654
Anderson-Darling	A-Sq	0.624721	Pr > A-Sq	0.1021

## Lampiran 46. Pemodelan ARIMAX ke-1 *Inflow* Uang Kartal (Semua Parameter)

Conditional Least Squares Estimation							
Parameter	Estimate	Standard Error	t Value	Approx Pr >  t	Lag	Variable	Shift
MA1,1	0.23821	0.10219	2.33	0.0215	24	y	0
AR1,1	0.30802	0.09147	3.37	0.0010	3	y	0
NUM1	-0.0046383	0.0024103	-1.92	0.0567	0	t	0
NUM2	-1.87163	0.22654	-8.26	<.0001	0	I1	0
NUM3	-0.84888	0.31705	-2.68	0.0085	0	I2	0
NUM4	0.02165	0.0040996	5.28	<.0001	0	tI1	0
NUM5	0.01593	0.0036554	4.36	<.0001	0	tI2	0
NUM6	1.54440	0.09541	16.19	<.0001	0	M1	0
NUM7	1.18545	0.09554	12.41	<.0001	0	M2	0
NUM8	1.22315	0.08935	13.69	<.0001	0	M3	0
NUM9	1.08399	0.09034	12.00	<.0001	0	M4	0
NUM10	1.10066	0.09046	12.17	<.0001	0	M5	0
NUM11	1.07186	0.09119	11.75	<.0001	0	M6	0
NUM12	1.22336	0.09191	13.31	<.0001	0	M7	0
NUM13	1.27156	0.09341	13.61	<.0001	0	M8	0
NUM14	1.14968	0.09469	12.14	<.0001	0	M9	0
NUM15	1.31410	0.09452	13.90	<.0001	0	M10	0
NUM16	1.22271	0.09575	12.77	<.0001	0	M11	0
NUM17	0.87062	0.09440	9.22	<.0001	0	M12	0
NUM18	0.86231	0.17095	5.04	<.0001	0	C1t	0
NUM19	0.56271	0.14082	4.00	0.0001	0	C2t	0
NUM20	0.21474	0.11825	1.82	0.0719	0	C3t	0
NUM21	-0.39011	0.13974	-2.79	0.0061	0	C4t	0
NUM22	0.10782	0.17047	0.63	0.5283	0	C1tp1	0
NUM23	0.36906	0.14221	2.60	0.0107	0	C2tp1	0
NUM24	0.40701	0.11870	3.43	0.0008	0	C3tp1	0
NUM25	0.53731	0.12057	4.46	<.0001	0	C4tp1	0
Variance Estimate				0.056337			
Std Error Estimate				0.237355			
AIC				18.55323			
SBC				98.73819			
Number of Residuals				144			
* AIC and SBC do not include log determinant.							

Autocorrelation Check of Residuals									
Lag	Square	DF	To ChiSq	Chi-	Pr >	-----Autocorrelations-----			
6	2.03	4	0.7304	0.018	0.053	-0.007	0.035	0.086	0.040
12	9.94	10	0.4454	-0.146	0.003	-0.013	-0.090	-0.045	-0.138
18	15.44	16	0.4927	0.069	-0.025	-0.049	-0.152	-0.039	-0.034
24	20.11	22	0.5761	-0.011	-0.061	-0.051	-0.098	0.102	0.025
30	27.29	28	0.5026	-0.002	0.088	-0.076	0.152	0.016	-0.052
36	35.19	34	0.4116	-0.015	-0.043	-0.076	-0.111	-0.040	-0.139

Tests for Normality				
Test	--Statistic--	-----p Value-----		
Shapiro-Wilk	W	0.988654	Pr < W	0.2914
Kolmogorov-Smirnov	D	0.053553	Pr > D	>0.1500
Cramer-von Mises	W-Sq	0.055794	Pr > W-Sq	>0.2500
Anderson-Darling	A-Sq	0.419867	Pr > A-Sq	>0.2500

Lampiran 47. Pemodelan ARIMAX ke-2 *Inflow* Uang Kartal  
(Semua Parameter)

Conditional Least Squares Estimation							
Parameter	Estimate	Standard Error	t Value	Approx Pr >  t	Lag	Variable	Shift
MA1,1	-0.29146	0.09186	-3.17	0.0019	3	y	0
MA1,2	0.20304	0.09453	2.15	0.0338	16	y	0
AR1,1	-0.19678	0.09920	-1.98	0.0497	24	y	0
NUM1	-0.0050972	0.0022608	-2.25	0.0260	0	t	0
NUM2	-1.75229	0.21453	-8.17	<.0001	0	I1	0
NUM3	-0.84489	0.27831	-3.04	0.0030	0	I2	0
NUM4	0.01999	0.0038926	5.13	<.0001	0	tI1	0
NUM5	0.01630	0.0032780	4.97	<.0001	0	tI2	0
NUM6	1.54966	0.09128	16.98	<.0001	0	M1	0
NUM7	1.19033	0.09168	12.98	<.0001	0	M2	0
NUM8	1.23143	0.08608	14.31	<.0001	0	M3	0
NUM9	1.09199	0.08700	12.55	<.0001	0	M4	0
NUM10	1.10975	0.08707	12.75	<.0001	0	M5	0
NUM11	1.08438	0.08751	12.39	<.0001	0	M6	0
NUM12	1.22827	0.08834	13.90	<.0001	0	M7	0
NUM13	1.27336	0.08978	14.18	<.0001	0	M8	0
NUM14	1.16036	0.09162	12.66	<.0001	0	M9	0
NUM15	1.31938	0.09189	14.36	<.0001	0	M10	0
NUM16	1.23699	0.09231	13.40	<.0001	0	M11	0
NUM17	0.88668	0.09014	9.84	<.0001	0	M12	0
NUM18	0.81875	0.17460	4.69	<.0001	0	C1t	0
NUM19	0.58828	0.14005	4.20	<.0001	0	C2t	0
NUM20	0.20537	0.11843	1.73	0.0856	0	C3t	0
NUM21	-0.32862	0.13706	-2.40	0.0181	0	C4t	0
NUM22	0.07243	0.17038	0.43	0.6715	0	C1tp1	0
NUM23	0.37599	0.14021	2.68	0.0084	0	C2tp1	0
NUM24	0.41898	0.11830	3.54	0.0006	0	C3tp1	0
NUM25	0.57946	0.12191	4.75	<.0001	0	C4tp1	0
Variance Estimate				0.056222			
Std Error Estimate				0.237112			
AIC				19.02162			
SBC				102.1764			
Number of Residuals				144			
* AIC and SBC do not include log determinant.							

Autocorrelation Check of Residuals									
Lag	Square	DF	To ChiSq	Chi-	Pr >	Autocorrelations-----			
6	2.38	3	0.4978	0.007	0.048	0.041	-0.014	0.067	0.084
12	8.63	9	0.4725	-0.137	0.006	-0.065	-0.078	-0.044	-0.094
18	11.78	15	0.6958	0.052	-0.038	-0.084	-0.009	-0.040	-0.080
24	16.73	21	0.7271	-0.080	-0.099	-0.036	-0.079	0.069	-0.022
30	22.76	27	0.6977	0.002	0.092	-0.069	0.135	0.031	-0.033
36	28.84	33	0.6746	-0.008	-0.048	0.054	-0.094	-0.035	-0.127

Tests for Normality				
Test	--Statistic--	----p Value-----		
Shapiro-Wilk	W	0.989686	Pr < W	0.3694
Kolmogorov-Smirnov	D	0.049643	Pr > D	>0.1500
Cramer-von Mises	W-Sq	0.055182	Pr > W-Sq	>0.2500
Anderson-Darling	A-Sq	0.384798	Pr > A-Sq	>0.2500

## Lampiran 48. Pemodelan ARIMAX ke-1 *Inflow* Uang Kartal (Parameter Signifikan)

Conditional Least Squares Estimation							
Parameter	Estimate	Standard Error	t Value	Approx Pr >  t	Lag	Variable	Shift
MA1,1	0.26319	0.09863	2.67	0.0087	24	y	0
AR1,1	0.31447	0.08981	3.50	0.0007	3	y	0
NUM1	-1.78405	0.22775	-7.83	<.0001	0	I1	0
NUM2	-0.69786	0.32204	-2.17	0.0322	0	I2	0
NUM3	0.01741	0.0035404	4.92	<.0001	0	tI1	0
NUM4	0.01091	0.0027347	3.99	0.0001	0	tI2	0
NUM5	1.42114	0.07066	20.11	<.0001	0	M1	0
NUM6	1.06025	0.07060	15.02	<.0001	0	M2	0
NUM7	1.12239	0.07368	15.23	<.0001	0	M3	0
NUM8	0.98154	0.07346	13.36	<.0001	0	M4	0
NUM9	0.99701	0.07336	13.59	<.0001	0	M5	0
NUM10	0.96637	0.07307	13.23	<.0001	0	M6	0
NUM11	1.13469	0.07509	15.11	<.0001	0	M7	0
NUM12	1.18964	0.07646	15.56	<.0001	0	M8	0
NUM13	1.06427	0.07630	13.95	<.0001	0	M9	0
NUM14	1.21563	0.07834	15.52	<.0001	0	M10	0
NUM15	1.14145	0.07536	15.15	<.0001	0	M11	0
NUM16	0.76951	0.07332	10.50	<.0001	0	M12	0
NUM17	0.84789	0.17246	4.92	<.0001	0	C1t	0
NUM18	0.54084	0.14290	3.78	0.0002	0	C2t	0
NUM19	-0.42366	0.14117	-3.00	0.0033	0	C4t	0
NUM20	0.37017	0.14428	2.57	0.0115	0	C2tp1	0
NUM21	0.39111	0.12064	3.24	0.0015	0	C3tp1	0
NUM22	0.54237	0.12255	4.43	<.0001	0	C4tp1	0
Variance Estimate				0.058564			
Std Error Estimate				0.242			
AIC				21.78065			
SBC				93.05617			
Number of Residuals				144			
* AIC and SBC do not include log determinant.							

Autocorrelation Check of Residuals									
Lag	Square	DF	To ChiSq	Chi-	Pr >	-----Autocorrelations-----			
6	1.97	4	0.7415	0.005	0.017	-0.018	0.043	0.069	0.076
12	9.39	10	0.4953	-0.093	0.030	-0.013	-0.131	-0.022	-0.141
18	16.81	16	0.3983	0.111	-0.037	-0.049	-0.171	-0.001	-0.013
24	18.09	22	0.7007	0.003	-0.013	-0.018	-0.061	0.049	0.029
30	27.36	28	0.4985	-0.034	0.129	-0.083	0.137	-0.038	-0.080
36	34.27	34	0.4546	-0.019	0.016	0.042	-0.106	-0.039	-0.144

Tests for Normality				
Test	--Statistic--	-----p Value-----		
Shapiro-Wilk	W	0.986987	Pr < W	0.1950
Kolmogorov-Smirnov	D	0.047876	Pr > D	>0.1500
Cramer-von Mises	W-Sq	0.076276	Pr > W-Sq	0.2351
Anderson-Darling	A-Sq	0.489932	Pr > A-Sq	0.2252

Lampiran 49. Pemodelan ARIMAX ke-2 *Inflow* Uang Kartal  
(Parameter Signifikan)

Conditional Least Squares Estimation							
Parameter	Estimate	Standard Error	t Value	Approx Pr >  t	Lag	Variable	Shift
MA1,1	-0.26793	0.08961	-2.99	0.0034	3	y	0
MA1,2	0.20612	0.09415	2.19	0.0305	16	y	0
AR1,1	-0.22469	0.09639	-2.33	0.0214	24	y	0
NUM1	-1.66941	0.21179	-7.88	<.0001	0	I1	0
NUM2	-0.72816	0.27668	-2.63	0.0096	0	I2	0
NUM3	0.01524	0.0032641	4.67	<.0001	0	tI1	0
NUM4	0.01113	0.0023529	4.73	<.0001	0	tI2	0
NUM5	1.42526	0.07068	20.17	<.0001	0	M1	0
NUM6	1.06423	0.07063	15.07	<.0001	0	M2	0
NUM7	1.13312	0.07259	15.61	<.0001	0	M3	0
NUM8	0.99082	0.07258	13.65	<.0001	0	M4	0
NUM9	1.00684	0.07255	13.88	<.0001	0	M5	0
NUM10	0.97908	0.07240	13.52	<.0001	0	M6	0
NUM11	1.13926	0.07434	15.33	<.0001	0	M7	0
NUM12	1.19130	0.07546	15.79	<.0001	0	M8	0
NUM13	1.07155	0.07546	14.20	<.0001	0	M9	0
NUM14	1.21573	0.07707	15.77	<.0001	0	M10	0
NUM15	1.14807	0.07468	15.37	<.0001	0	M11	0
NUM16	0.78198	0.07244	10.79	<.0001	0	M12	0
NUM17	0.83350	0.17589	4.74	<.0001	0	C1t	0
NUM18	0.57367	0.14338	4.00	0.0001	0	C2t	0
NUM19	-0.36177	0.14022	-2.58	0.0111	0	C4t	0
NUM20	0.38013	0.14339	2.65	0.0091	0	C2tp1	0
NUM21	0.40293	0.12161	3.31	0.0012	0	C3tp1	0
NUM22	0.56723	0.12549	4.52	<.0001	0	C4tp1	0
Variance Estimate				0.058689			
Std Error Estimate				0.242259			
AIC				22.88302			
SBC				97.12835			
Number of Residuals				144			
* AIC and SBC do not include log determinant.							

Autocorrelation Check of Residuals									
Lag	Square	DF	To ChiSq	Chi-	Pr >	Autocorrelations-----			
6	2.80	3	0.4236	-0.010	-0.008	0.046	-0.012	0.054	0.115
12	8.32	9	0.5027	-0.099	0.029	-0.057	-0.101	-0.038	-0.098
18	11.63	15	0.7071	0.080	-0.049	-0.092	-0.014	-0.006	-0.054
24	13.08	21	0.9059	-0.059	-0.034	0.003	-0.053	0.020	-0.026
30	20.71	27	0.7997	-0.029	0.126	-0.083	0.114	-0.012	-0.073
36	25.90	33	0.8056	-0.029	0.008	0.030	-0.073	-0.040	-0.135

Tests for Normality				
Test	--Statistic--	----p Value-----		
Shapiro-Wilk	W	0.988275	Pr < W	0.2664
Kolmogorov-Smirnov	D	0.055138	Pr > D	>0.1500
Cramer-von Mises	W-Sq	0.0737	Pr > W-Sq	>0.2500
Anderson-Darling	A-Sq	0.455098	Pr > A-Sq	>0.2500

## Lampiran 50. Pemodelan Ramalan ARIMAX *Outflow* Uang Kartal 12 Bulan Kedepan

Conditional Least Squares Estimation							
Parameter	Estimate	Standard Error	t Value	Approx Pr >  t	Lag	Variable	Shift
AR1,1	-0.15828	0.08488	-1.86	0.0646	1	y	0
AR1,2	0.27250	0.08347	3.26	0.0014	2	y	0
AR1,3	-0.28321	0.08499	-3.33	0.0011	13	y	0
AR1,4	-0.22911	0.08796	-2.60	0.0103	14	y	0
AR2,1	0.21374	0.09235	2.31	0.0223	12	y	0
NUM1	-0.0058302	0.0064267	-0.91	0.3660	0	t	0
NUM2	-2.73278	0.27119	-10.08	<.0001	0	I1	0
NUM3	-2.20796	0.29542	-7.47	<.0001	0	I2	0
NUM4	0.02555	0.0072248	3.54	0.0006	0	tI1	0
NUM5	0.02662	0.0067692	3.93	0.0001	0	tI2	0
NUM6	-0.03348	0.18855	-0.18	0.8593	0	M1	0
NUM7	0.28963	0.19127	1.51	0.1325	0	M2	0
NUM8	0.58857	0.19328	3.05	0.0028	0	M3	0
NUM9	0.81626	0.19398	4.21	<.0001	0	M4	0
NUM10	0.68979	0.19511	3.54	0.0006	0	M5	0
NUM11	0.95310	0.19990	4.77	<.0001	0	M6	0
NUM12	0.75330	0.20309	3.71	0.0003	0	M7	0
NUM13	0.33090	0.20191	1.64	0.1037	0	M8	0
NUM14	0.59129	0.20144	2.94	0.0040	0	M9	0
NUM15	0.44493	0.20519	2.17	0.0320	0	M10	0
NUM16	0.60883	0.20164	3.02	0.0031	0	M11	0
NUM17	1.38664	0.20276	6.84	<.0001	0	M12	0
NUM18	-0.59473	0.21974	-2.71	0.0077	0	C1t	0
NUM19	1.56132	0.21818	7.16	<.0001	0	C2t	0
NUM20	1.16804	0.19408	6.02	<.0001	0	C3t	0
NUM21	1.65684	0.22766	7.28	<.0001	0	C4t	0
NUM22	1.79130	0.22619	7.92	<.0001	0	C1t1	0
NUM23	1.13058	0.22451	5.04	<.0001	0	C2t1	0
NUM24	0.29532	0.19721	1.50	0.1368	0	C3t1	0
NUM25	0.45039	0.19382	2.32	0.0217	0	C4t1	0
Variance Estimate				0.147707			
Std Error Estimate				0.384327			
AIC				171.0374			
SBC				262.533			
Number of Residuals				156			

Autocorrelation Check of Residuals									
Lag	Square	DF	To ChiSq	Chi-	Pr >	-----Autocorrelations-----			
6	0.93	1	0.3341	-0.041	-0.041	0.002	0.030	0.039	0.005
12	4.37	7	0.7359	0.117	-0.063	-0.020	-0.045	0.017	0.019
18	8.11	13	0.8363	0.022	-0.025	-0.087	-0.022	-0.105	0.033
24	16.03	19	0.6552	-0.046	0.040	-0.019	-0.178	0.019	-0.083
30	17.69	25	0.8553	0.052	-0.020	-0.020	-0.017	0.047	-0.051
36	21.11	31	0.9089	0.072	0.010	-0.034	-0.017	-0.101	-0.007

Tests for Normality					
Test	--Statistic--	-----p Value-----			
Shapiro-Wilk	W	0.988426	Pr < W	0.2258	
Kolmogorov-Smirnov	D	0.051158	Pr > D	>0.1500	
Cramer-von Mises	W-Sq	0.063931	Pr > W-Sq	>0.2500	
Anderson-Darling	A-Sq	0.419569	Pr > A-Sq	>0.2500	

## Lampiran 51. Pemodelan Ramalan ARIMAX *Inflow* Uang Kartal 12 Bulan Kedepan

Conditional Least Squares Estimation							
Parameter	Estimate	Standard Error	t Value	Approx Pr >  t	Lag	Variable	Shift
MA1,1	0.22210	0.09439	2.35	0.0201	24	y	0
AR1,1	0.33649	0.08491	3.96	0.0001	3	y	0
NUM1	-1.76918	0.22388	-7.90	<.0001	0	I1	0
NUM2	-0.47670	0.25256	-1.89	0.0613	0	I2	0
NUM3	0.01728	0.0034844	4.96	<.0001	0	tI1	0
NUM4	0.0089621	0.0020121	4.45	<.0001	0	tI2	0
NUM5	1.42275	0.07008	20.30	<.0001	0	M1	0
NUM6	1.05798	0.07012	15.09	<.0001	0	M2	0
NUM7	1.10257	0.07290	15.13	<.0001	0	M3	0
NUM8	0.36984	0.07288	13.31	<.0001	0	M4	0
NUM9	0.99712	0.07271	13.71	<.0001	0	M5	0
NUM10	0.95590	0.07253	13.18	<.0001	0	M6	0
NUM11	1.12168	0.07501	14.95	<.0001	0	M7	0
NUM12	1.18669	0.07568	15.68	<.0001	0	M8	0
NUM13	1.06273	0.07506	14.16	<.0001	0	M9	0
NUM14	1.20068	0.07589	15.82	<.0001	0	M10	0
NUM15	1.12370	0.07385	15.22	<.0001	0	M11	0
NUM16	0.78136	0.07249	10.78	<.0001	0	M12	0
NUM17	0.81275	0.13406	6.06	<.0001	0	C1t	0
NUM18	0.54571	0.13688	3.99	0.0001	0	C2t	0
NUM19	-0.41973	0.13557	-3.10	0.0024	0	C4t	0
NUM20	0.39655	0.13821	2.87	0.0048	0	C2tp1	0
NUM21	0.40110	0.11589	3.46	0.0007	0	C3tp1	0
NUM22	0.55245	0.11788	4.69	<.0001	0	C4tp1	0
Variance Estimate				0.055266			
Std Error Estimate				0.235088			
AIC				12.93557			

Autocorrelation Check of Residuals								
Lag	Square	DF	To ChiSq	Chi-	Pr >	-----Autocorrelations-----		
6	3.10	4	0.5409	0.016	0.009	-0.021	0.059	0.085
12	8.87	10	0.5449	-0.060	0.041	-0.028	-0.123	-0.111
18	17.35	16	0.3634	0.124	-0.021	-0.050	-0.173	0.006
24	19.22	22	0.6319	0.001	-0.006	-0.020	-0.080	0.052
30	27.75	28	0.4777	-0.035	0.105	-0.090	0.133	-0.048
36	34.71	34	0.4338	-0.015	0.016	0.031	-0.112	-0.061

Tests for Normality				
Test	--Statistic--	-----p Value-----		
Shapiro-Wilk	W	0.983769	Pr < W	0.0641
Kolmogorov-Smirnov	D	0.059161	Pr > D	>0.1500
Cramer-von Mises	W-Sq	0.101484	Pr > W-Sq	0.1084
Anderson-Darling	A-Sq	0.666087	Pr > A-Sq	0.0842

**Lampiran 52. Surat Keterangan Data Instansi****SURAT KETERANGAN**

Saya yang bertanda tangan di bawah ini, menerangkan bahwa:

I. Mahasiswa Jurusan Statistika FMIPA ITS:

Nama : Juliyanto

NRP : 1313 100 014

Telah mengambil data di instansi/perusahaan kami:

Nama Instansi : Kantor Perwakilan Bank Indonesia Provinsi  
Jawa Barat

Divisi/bagian : Divisi Advisory Ekonomi dan Keuangan

Sejak bulan Mei 2016 sampai dengan 29 Februari 2017 untuk keperluan Tugas Akhir Semester Genap 2016/2017.

Bandung, 6 Juni 2017

Asisten Direktur



Wahyu Ari Wibowo

NIP. 13624

\*coret yang tidak perlu



## BIODATA PENULIS



Juliyanto, lahir di Cirebon, 07 Juli 1995. Anak ke empat dari empat bersaudara dari pasangan H. Andi S dan Hj. Uyi. Pendidikan formal penulis diawali di TK Zahratul Ulum, SD N 1 Karangampel Kidul, SMP N 5 Kota Cirebon, SMA N 2 Kota Cirebon, hingga jenjang S1 Statistika ITS pada tahun 2013 melalui jalur SNMPTN Undangan dengan Nomor Registrasi Peserta (NRP) 1313100014. Selama perkuliahan di Departemen Statistika, penulis aktif di organisasi UKM Bulutangkis ITS sejak MABA hingga tahun ke-4 dengan jabatan terakhir sebagai Kepala Departemen Hubungan Luar, Lembaga Minat Bakat ITS dengan jabatan terakhir sebagai Kordinator Bidang Olahraga dan Sobot Bumi Surabaya dengan jabatan terakhir sebagai Kepala Divisi PSDM. Apabila ada kritik, saran dan pertanyaan terkait Tugas Akhir ini, bisa menghubungi penulis di +6283823165296 / +6281334333825 atau email [juliyanto777@gmail.com](mailto:juliyanto777@gmail.com). Jiayou Badminton Indonesia!

*Halaman ini sengaja dikosongkan*